

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOFIZIČKI ODSJEK

Karol Ćorko

Analiza modeliranih vrijednosti tuče dobivenih
mezoskalnim numeričkim modelom

Diplomski rad

Zagreb, 2019.

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOFIZIČKI ODSJEK

DIPLOMSKI SVEUČILIŠNI STUDIJ FIZIKA-GEOFIZIKA
SMJER:
METEOROLOGIJA I FIZIČKA OCEANOGRAFIJA

KAROL ĆORKO

Diplomski rad

**Analiza modeliranih vrijednosti tuče
dobivenih mezoskalnim numeričkim
modelom**

Voditelj diplomskog rada: izv. prof. dr. sc. Maja Telišman Prtenjak

Povjerenstvo: 1. _____
2. _____
3. _____

Datum polaganja: _____

Zagreb, 2019.

Zahvale

Ovaj rad djelomično je financiran u okviru Hrvatsko-švicarskog istraživačkog programa Hrvatske zaklade za znanost i Švicarske nacionalne zaklade za znanost putem sredstava švicarsko-hrvatskog programa suradnje. Numeričke simulacije korištene u ovom radu dobivene su zahvaljujući projektu *Severe weather over the Alpine-Adriatic region in a changing climate*; SWALDRIC (Br. IZHRZO-180587).

Želio bih zahvaliti Kristianu Horvathu na provedenim numeričkim simulacijama. Barbari Malečić i Damjanu Jeliću na pomoći i savjetima pri izradi diplomskog rada.

Također zahvaljujem osoblju Državnog hidrometeorološkog zavoda na ustupljenim mjerenjima. Želio bih zahvaliti Antonu Zgoncu na ustupljenim podacima radarskih slika ARSO-a i prof. Hans-Dieter Betzu na ustupljenim LINET podacima.

Posebno bih zahvalio svojoj mentorici izv. prof. dr. sc. Maji Telišman Prtenjak na ideji, iznimnom trudu, strpljenju i korisnim savjetima prilikom izrade ovoga rada.

I na kraju, veliko hvala mojim roditeljima i bratu na svesrdnoj podršci.

Sažetak

U radu su analizirana dva događaja tuče simulirana modelom *WRF-HAILCAST*. Dosadašnje su analize pokazale neujednačenost opažanja tuče nad područjem Hrvatske. Podaci se uglavnom mjere/opažaju u nizinskom dijelu na meteorološkim postajama te lansirnim postajama u sklopu obrane od tuče. Dodatno je postavljen posebno dizajniran poligon guste mreže tučomjera u sjeverozapadnoj Hrvatskoj. Cilj rada bio je ispitati uspješnost modeliranja mezoskalnim modelom visoke razlučivosti i pružiti daljnje smjernice za podešavanje modela čime bi se pospješila prognoza tuče. Model je uspio reproducirati sinoptičke uvjete koji su djelovali u promatranom razdoblju odnosno uvjete koji potiču razvoj olujnog nevremena. U obje epizode model je precijenio područje pogođeno tučom. Unatoč tome, zabilježene maksimalne promjere tuče u slučaju iz 2014. model je uspješno prognozirao (prostorno i vremenski te kategoriju tuče). Međutim, u slučaju epizode iz 2017. model nije uspio prognozirati (ni prostorno ni vremenski) tuču na području na kojem je ona zabilježena.

Ključne riječi: tuča, WRF-HAILCAST

Analysis of modelled hail parameters obtained by numerical mesoscale model

Abstract

Former analyses showed disproportion in hail observations in Croatia. Due to a long history of hail suppression activities in the northern (lowland) part of Croatia, hailpads have been placed at main meteorological stations, locations used for hail suppression activities, as well as on a specifically designed polygon in north-western Croatia. Therefore, two selected hail events were simulated using the WRF-HAILCAST model and analysed in order to examine its performance in modelling and to provide guidance for tuning of hailcast results. The model successfully reproduced synoptic conditions favourable for developing stormy weather over northern Croatia during the analysed period. In both episodes, the model overestimated the affected area. Nevertheless, the measured maximum hail diameters in the 2014 episode were successfully captured (both spatially and temporally). However, for the 2017 episode, the measured maximum hail diameters were not forecasted (spatially nor temporally).

Keywords: hail, WRF-HAILCAST

Sadržaj:

1 Uvod	1
1.1 Kumulonimbus	1
1.2 Tuča	3
1.3 Tučomjer i veličine kojima opisujemo tuču	4
1.4 Istraživanje tuče u Europi i Hrvatskoj	5
1.4.1 Istraživanje dostupnih podataka o tuči u Europi	5
1.4.2 Istraživanje dostupnih podataka o tuči u Hrvatskoj	9
1.5 Motivacija i cilj rada	10
2 Podaci i metode	12
2.1 Geografski i klimatološki opis domene	12
2.2 Mjerne postaje i podaci	13
2.3 Računanje relativne vlažnosti rh	13
2.4 Odabrani slučajevi	14
2.5 Model WRF i WRF-HAILCAST	14
2.5.1 Opće karakteristike i postavke modela WRF	14
2.5.2 Izvorni HAILCAST model	15
2.5.3 Implementacija HAILCAST modela u WRF model	16
2.5.4 Modifikacije WRF-HAILCAST modela	18
2.5.5 Statistički parametri korišteni u evaluaciji modela	19
3 Karakteristike odabranih epizoda i usporedba s modelom	20
3.1 Karakteristike slučaja 30.-31. srpnja 2014.	20
3.2 Analiza rezultata WRF modela za slučaj 30.-31. srpnja 2014.	23
3.2.1 Evaluacija modela po postajama za slučaj 30.-31. srpnja 2014.	23
3.2.2 Analiza modeliranih meteoroloških polja za slučaj 30.-31. srpnja 2014.	27
3.3 Karakteristike slučaja 16.-17. rujna 2017.	33
3.4 Analiza rezultata WRF modela za slučaj 16.-17. rujna 2017.	36
4 Zaključak	44
Literatura	46

1 Uvod

1.1 Kumulonimbus

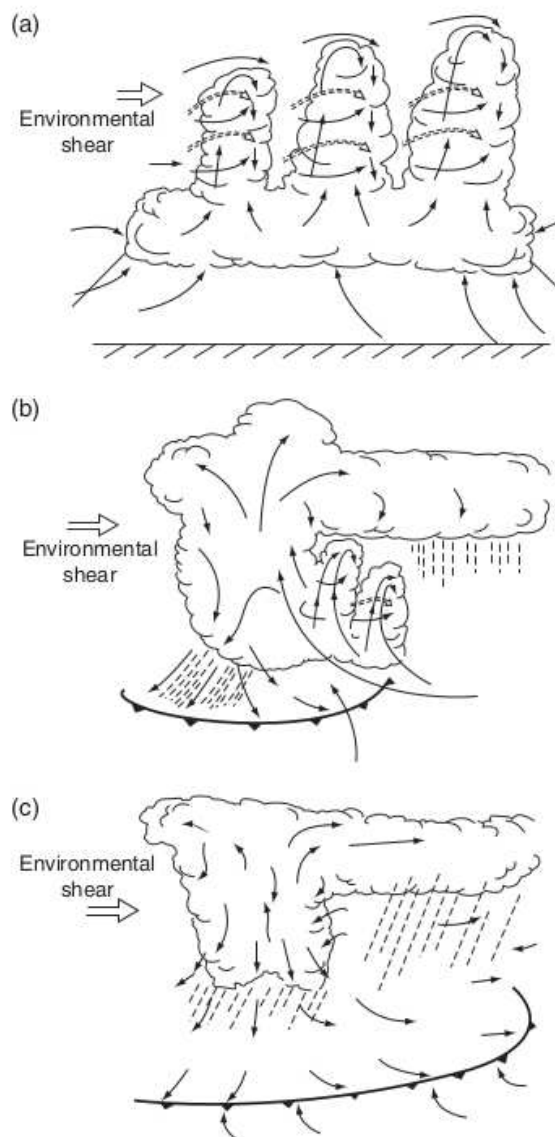
Konvekција je prijenos topline strujanjem zraka u više slojeve atmosfere. Prilikom jakih konvektivnih strujanja dolazi do razvoja konvektivnih oblaka (kumulus i kumulonimbus). Kumulonimbus (Cb) je krupan i gust oblak velikog vertikalnog razvoja s gornjim dijelom koji se često širi u obliku nakovnja ili velike perjanice (Slika 1). Pod podnicom ovog oblaka, koja je vrlo tamna, često se nalaze niski čupavi oblaci spojeni s njome, katkad i oborine u obliku virge (WMO, 1975.). S obzirom na to da uzrokuje oluje, često se naziva i olujnim oblakom.



Slika 1: Prikaz kumulonimbusa s karakterističnim nakovnjem. (izvor: <https://cloudatlas.wmo.int/cumulonimbus-cb.html>)

Cb se sastoji od jednog ili više aktivnih centara, tzv. ćelija (Byers i Braham, 1949.; Browning, 1977.; Cotton *et al.*, 2010.). Obično se radarom uočavaju kao područja intenzivne oborine ili lokalni maksimum refleksivnosti radarskog odraza. Odlikuju ih snažna uzlazna i silazna strujanja zraka s naglašenom mikrofizičkom i električnom aktivnošću. Svaka ćelija u svom životnom ciklusu prolazi kroz tri faze razvoja (Byers i Braham, 1949.): faza nastajanja (kumulusna faza), zrelosti i rasipanja (Slika 2). U fazi nastajanja uzlazno strujanje zauzima gotovo cijelu ćeliju. Karakterizira ju jedan ili više oblaka u obliku tornjeva koje hrani konvergencija vlažnog zraka nižih slojeva. Spajanje kumulusnih elemenata u veći konvektivni sustav predstavlja tranziciju u zrelu fazu. Zrelu fazu odlikuju uzlazna i silazna strujanja te jaki lokalizirani pljuskovi. Uzlazna strujanja mogu se protezati duž cijele troposfere. Divergencija uzlaznih strujanja u podnožju tropopauze rezultira stvaranjem nakovnja, a nerijetko i kupole koja predstavlja pojavu kupolaste strukture iznad nakovnja Cb (eng. *overshooting top*, OT) odnosno probijanja uzlaznih gibanja do sloja stabilne stratosfere. Blizu tla, divergencija silaznog strujanja zraka ohlađenog evaporacijom i topljenjem oborine formira frontu udara vjetra. Ona forsira uzdizanje toplog, vlažnog i nestabilnog zraka za daljnji razvoj novih kumulusa. U trećoj fazi, odnosno fazi rasipanja, dominira silazno, a zamire uzlazno strujanje. Fronta

udara vjetra udaljava se od oblaka i više ne potiče uzlazno strujanje. Nadalje, prevladava lagana i stalna oborina.



Slika 2: Shema životnog vijeka kumulonimbusa: (a) kumulusna faza, (b) zrela faza tijekom koje se razvija oborina i oblik nakovnja i (c) završna faza (izvor: Cotton *et al.*, 2010.).

Postoje mnogi pokušaji klasifikacija olujnih oblaka (npr. Browning, 1977.). Browning (1977.) je olujni oblak koji prolazi kroz tri faze razvoja u periodu od 45-60 minuta i čija zrela faza traje 15-30 minuta nazvao „uobičajeni” olujni oblak. Ako je olujni oblak sastavljen od dviju do četiriju ćelija, a vertikalno smicanje vjetra u donjih 4 km umjereno je jako (~ 10 do 20 m/s), nazivamo ga multićelijskim. Multićelijski Cb-i proizvode kvaziperiodične pljuskove u trajanju od nekoliko sati ili dulje, ovisno o postojanju mehanizma obnavljanja multićelija, što može dovesti do lokalnih poplava. Grupa multićelija može stvoriti olujnu mezoskalnu frontu, s izuzetno jakim horizontalnim smicanjem vjetra, grmljavinom i jakim pljuskovima. Takve olujne formacije često se nazivaju olujnim prugama (eng. *squall-line*). U bilo kojem trenutku, dio ćelija može biti u prvoj ili drugoj fazi razvoja dok su druge u fazi rasipanja. Dio studija spominje bočne

kumulusne tornjeve kao oblake hranioce (Dennis *et al.*, 1970.) iz razloga što se nove ćelije spajaju s „roditeljskom“ ćelijom. Ostali (npr. Browning, 1977.) ih nazivaju ćelijama „kćerima“ pri čemu se nove ćelije ne spajaju s „roditeljskom“, nego rastu ubrzano kako bi postale nova središta oluje. Tada starija „roditeljska“ ćelija umire. Nove se ćelije formiraju u intervalima od 5-10 minuta, a životni vijek im je 20-30 minuta. Općenito su multićelijski Cb-i nešto manje intenzivni od superćelijskih. Superćelijske Cb-e raspoznamo po veličini i intenzitetu pri čemu uzlazna i silazna strujanja supostoje u gotovo ravnotežnim stanjima u periodima od 30 minuta ili dulje. Superćelije mogu biti samostalne ili međusobno organizirane (mezoskalni konvektivni sustav (eng. *mesoscale convective system*) koji često dovodi do poplava). Jedna od osnovnih osobina im je razvoj vlastite rotacije. Mnoge superćelije proizvedu karakteristični zavijutak u Doppler-radarskom odrazu polja brzine („kuka“ ili „udica“), što je najčešći znak tornadogeneze. Nadalje, superćelijska nevremena mogu se klasificirati u tri skupine: klasične, jako-oborinske (eng. *high-precipitation*, HP) i slabo oborinske (eng. *low-precipitation*, LP) superćelije (npr. Doswell *et al.*, 1990.). Klasične superćelije često su povezane s pojavom tornada, umjerenom oborinom i često proizvedu tuču velikih razmjera. LP proizvede vrlo malo oborine s učestalom jakom tučom, povremeno proizvede tornado i uglavnom je manja od klasične superćelije. HP odlikuje rasprostranjena oborina sa silovitom kišom i tučom koja prouzrokuje velike štete. Svi Cb-i mogu proizvesti munje i grmljavinu ako imaju dovoljno ledenih kristala.

1.2 Tuča

Tuča je kruta oborina sastavljena od komadića leda ili zrna, čiji je promjer prema dogovoru Svjetske meteorološke organizacije (WMO, 1992.) veći od 5 mm (Slika 3). Može biti prozirna, djelomično prozirna ili potpuno neprozirna. Općenito je sferičnog, stožastog ili nepravilnog oblika. Tuča nastaje u olujama s dubokom konvekcijom koje karakteriziraju jaka uzlazna strujanja, velike količine superohlađene tekuće vode, visoki vrhovi oblaka i dovoljno dugi životni vijek (npr. Houze, 2014.). Nevremena s tučom općenito su visoko organizirani konvektivni sustavi u smislu multićelijskih mezoskalnih konvektivnih sustava ili superćelijskih oluja. Rast zrna tuče ovisi o složenoj interakciji između strujanja zraka unutar konvektivnog oblaka i čestica oborine. Zrnca tuče ponajprije rastu skupljanjem superohlađenih kapi oblaka i kiše. U uzlaznom strujanju unutar oluje također postoje čestice leda zbog prisutnosti zamrznutih jezgri, ali je ipak najveći dio hidrometeora u obliku superohlađene vode (kapi kiše i oblaka mogu biti nezamrznute do $-40\text{ }^{\circ}\text{C}$). Nakon otprilike pet do deset minuta rasta kristalića leda uslijed depozicije vodene pare, ledeni kristalići steknu dovoljnu masu da padaju u odnosu na superohlađene kapi oblaka koje se zamrznju čim dođu u kontakt s kristalićima leda.

Nakupljanje superohlađenih kapi dovodi do stvaranja zrna približno sfernog oblika promjera od nekoliko milimetara. Kako čestice leda rastu, brže padaju i posljedično nakupljaju sve više superohlađene kapi zbog većeg poprečnog presjeka, što dovodi do veće brzine rasta. Kada brzina rasta dosegne visoke vrijednosti, temperatura zrna tuče može prijeći $0\text{ }^{\circ}\text{C}$ zbog energije koja je prenesena ledu u procesima fuzije pa se

superohlađene kapi koje dođu u kontakt neće istovremeno zalediti, nego će teći površinom zrna tuče popunjavajući praznine između već zaleđenih dijelova. Na taj način dolazi do povećanja gustoće i stvaranja sloja prozirnog leda. Ovaj postupak traje sve dok se zrno tuče nalazi u području bogatom superohlađenom tekućom vodom. Konačna veličina koju zrno tuče može poprimiti jest funkcija koncentracije tekuće vode i vremena provedenog u području koje je bogato superohlađenom tekućom vodom. Ukupno vrijeme obitavanja u tom području ovisi o snazi uzlaznog strujanja, brzini opadanja zrna tuče i mogućnosti zrna da se više puta nađe u području uzlaznog gibanja. Razvoj zrna tuče od malog embrija do velikog zrna ovisi i o složenoj interakciji strujanja zraka i mikrofizičkih procesa u oblaku. Ako je uzlazno strujanje prejako, maleno će se zrno izbaciti visoko iznad područja bogatog superohlađenom vodom. S druge strane, ako je uzlazno gibanje preslabo da zadrži zrno dok raste, prerano će se izbaciti iz oblaka. Veličina tuče koja padne na tlo također ovisi o otapanju prilikom pada. Ako je razina zamrzavanja visoka i zrno tuče pada (tj. nije izbačeno) kroz područje uzlaznog gibanja, može doći do značajnog otapanja, čak i prije nego što izađe iz oblaka. Nadalje, zrna tuče mogu padati iz područja silaznog strujanja zraka. U tom slučaju, zrno tuče brže padne na tlo i stoga je veće jer je dostupno manje vremena za otapanje.




Slika 3: Prikaz tuče (izvor: <https://cloudatlas.wmo.int/hail.html>)

1.3 Tučomjer i veličine kojima opisujemo tuču

Mjerenje i registracija pojave zrna tuče na tlu je zbog vremenskih i prostornih varijacija te kratkog trajanja vrlo složeno. Instrument za registraciju i mjerenje tuče na tlu naziva se tučomjer (Slika 4). Sastoji se od stalka (na 1 m visine od tla) i horizontalno postavljene tučomjerne ploče koja je napravljena od mekog materijala dimenzija 25 cm x 25 cm x 2 cm (Kuraži i Počakal, 2016.). Kako bi zrna tuče udarom ostavila trag na ploči,

materijal od koje je napravljena mora biti mekan, ali dovoljno otporan na djelovanje raznih vanjskih utjecaja. Gornja se ploča premazuje tankom bijelom bojom da bi se zaštitila od ultraljubičastog zračenja. Na temelju mjerenja dimenzija i broja otisaka koja zrna ostave na ploči utvrđuje se veličina zrna tuče. Mogu se koristiti materijali različite tvrdoće i elastičnosti pa je ploče tučomjera potrebno kalibrirati kako bi se usporedbom traga kugle poznatog promjera i traga zrna tuče mogao odrediti stvarni promjer zrna tuče koje je palo na ploču tučomjera (npr. Schleusener i Jennings, 1960.; Palencia *et al.*, 2007.). Pomoću veličine otiska traga odredi se stvarna veličina zrna koja su pala te se izračunava njihova ukupna masa i kinetička energija (metoda Mezeixa i Dorasa, 1981.). Kinetička energija (KE) jedna je od temeljnih varijabli jer se s pomoću nje može izmjeriti intenzitet tuče koji je izravno povezan s prouzročenom štetom. Dobiveni podaci jedne ploče tučomjera o vremenu i fizičkim parametrima su sljedeći: a) datum, b) vrijeme i trajanje padanja tuče, c) maksimalni promjer zrna (mm), d) ukupni broj zrna/m² za svaki interval (2.5 mm) veličine: 5.0-7.5; 7.6-10.0; 10.1-12.5; ... 37.5-40.0 mm, e) srednji promjer svih zrna (mm), f) masa (g/m²) g), KE (J/m²), h) oznaka tučomjera.



Slika 4: a) Tučomjer (stalak i ploča) i b) Tragovi tuče na ploči (izvor: [Počakal, 2012.](#))

1.4 Istraživanje tuče u Europi i Hrvatskoj

1.4.1 Istraživanje dostupnih podataka o tuči u Europi

Zbog lokalne prostorne skale zahvaćene tučom i nedostatkom adekvatnih sustava za opažanje u većini regija, oluje s tučom nisu precizno i sveobuhvatno zabilježene. To čini poteškoće u statističkoj analizi frekventnosti i klimatologije tuče. Gustoća mreže postaja je pregruba da bi pouzdano zabilježila lokalnu pojavu tuče te su često opažanja o pojavi tuče dostupna samo tijekom dana. Nadalje, motritelji uslijed vizualne procjene dimenzije zrna mogu pogrešno sugradicu i zaleđenu kišu označiti kao tuču. Postoji

nekoliko izvora informacija o pojavi tuče. Jedan izvor potječe iz *mreže tučomjera* postavljenih u određenim krajevima u Europi kao što su Francuska, sjeverna Italija, istočna Austrija, dijelovi Španjolske, Grčke i Hrvatske (npr. Punge i Kunz, 2016.). Druga grupa informacija uključuje iznose o *šteti od strane osiguravajućih društava* (sektori poljoprivrede i nekretnina), novinskih izvještaja ili kronika. U današnje vrijeme, navedeni podaci, usklađeni s opažanjima posebno istreniranih promatrača oluja, uneseni su u arhive snažnih oluja kao što je to baza podataka o opasnim vremenskim nepogodama odnosno olujama u Europi ([ESWD – European Severe Weather Database, https://www.eswd.eu/](https://www.eswd.eu/)). Treći je pristup procijeniti događaj tuče iz podataka dobivenih *daljinskim mjerenjima* kao što su radari i sateliti. Radari velike prostorne i vremenske rezolucije koji imaju velike površine pod stalnim nadzorom mogu upućivati na pojavu tuče. Signali za tuču mogu se procijeniti iz radarskog odraza iznad određenog praga (npr. Stržinar i Skok, 2018.) odnosno radarskog odraza pod različitim kutovima elevacije u kombinaciji s drugim meteorološkim podacima (npr. Holleman, 2001.). Nadalje, satelitska opažanja temeljena na temperaturi vrha oblaka i otkrivanju OT također su korištena kao indikator za pojavu tuče (npr. Mikuš Jurković *et al.*, 2015.).

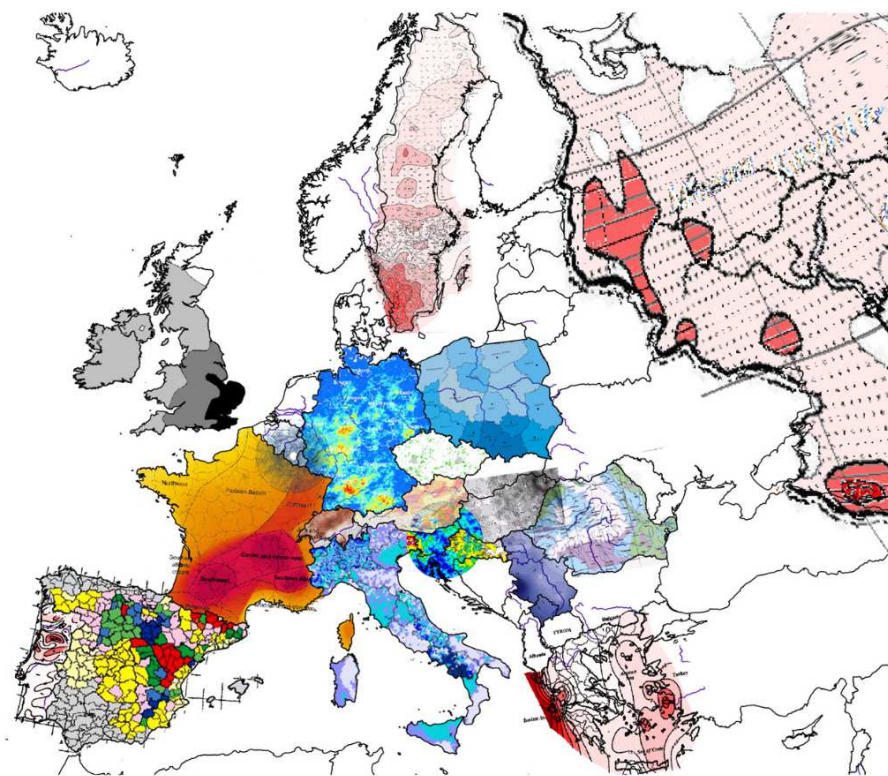
Najopćenitija definicija frekvencije tuče jest broj događaja tuče u godini na određenoj lokaciji, gdje se pod lokacijom smatra puno manje područje od čitavog zahvaćenog područja, ali dovoljno veliko da bude pouzdano pogođeno olujom.

U **sjevernoj Europi** tuča je manje prisutna nego u ostalim dijelovima Europe zbog hladnije klime (Slika 5). Blizina mora, osobito hladnog sjevernog Atlantika sprječava jaku konvektivnu aktivnost. U Danskoj i Norveškoj tuča je rijetka pojava (Tuovinen *et al.*, 2009.; Punge i Kunz, 2016.). Navedeni autori također su pokazali da se u Norveškoj učestalost tuče povećava prema jugoistoku. To je područje u kojemu je izmjeren najveći promjer tuče koji iznosi 100 mm. U Danskoj, prema izvještaju ESWD-a, najveća izmjerena tuča promjera je 40 mm. Za razliku od tih dviju zemalja, tuča u Švedskoj nešto je uobičajenija pojava jer je zaštićena planinama od oceanskog utjecaja prilikom zapadnih strujanja. Najveća zabilježena tuča prema ESWD-u je promjera 80 mm. Na Islandu do velike tuče rijetko dolazi i postoje samo tri takva izvješća u ESWD-u.

Na frekvenciju tuče na području **zapadne Europe** prvotno utječe Atlantski ocean koji potiče statičku stabilnost uslijed prigušenog dnevnog i sezonskog hoda temperature. Zbog toga ona bitno varira u zapadnoj Europi (Punge *et al.*, 2014.). Dok je Francuska često pod utjecajem snažnih nevremena, u zemljama Beneluksa i na Britanskim otocima pojava tuče je rijetka. Ipak karakterizira ih velika gustoća sustava niskog tlaka i fronti, što dovodi do čestih pojava sugradice i male tuče. Najveće zrno tuče izmjereno u Francuskoj imalo je promjer 150 mm i težilo 972 g (Strasbourg, 11. kolovoza 1958.; Jalu, 1959.).

Središnja Europa je u velikoj mjeri izložena opasnosti od tuče, osobito Njemačka, Švicarska i Austrija, gdje su dostupna opsežna istraživanja o frekvenciji tuče (Slika 5). Može se pretpostaviti da se frekvencija tuče smanjuje od zapada prema istoku i od juga prema sjeveru. Dublje nad kontinentom smanjuje se sadržaj vlage te slabe frontalni sustavi, što daje nepovoljnije uvjete za konvektivnu aktivnost. Općenito, frekvencija tuče pojačana je u predalpskom području Švicarske, Austrije i Slovenije. Tako su u Austriji, Štajerska (južni dijelovi), Salzburg i Gornja Austrija najskloniji pojavi tuče. Nasuprot

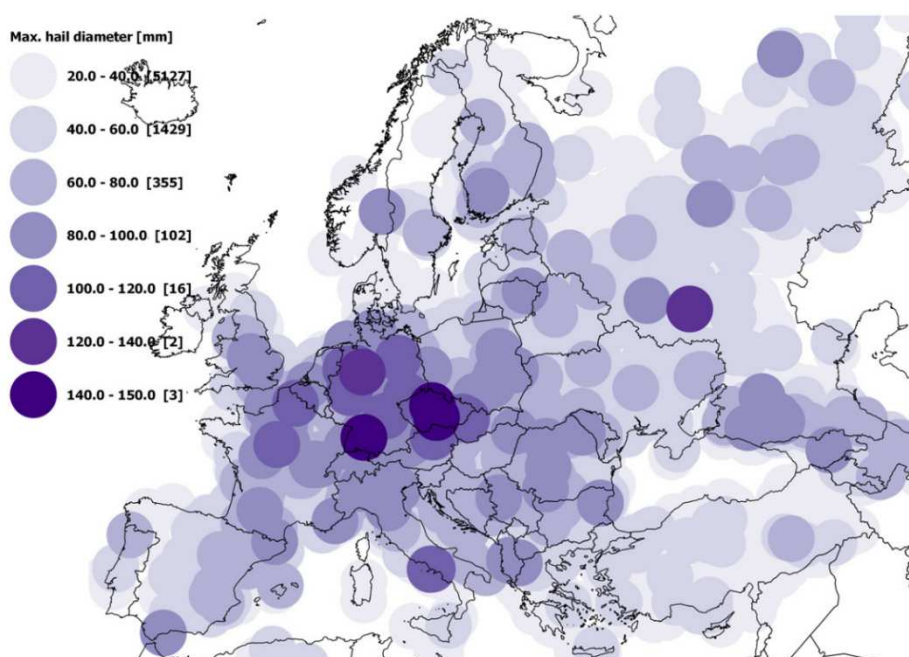
tome, u središnjim Alpama, u području između najviših vrhova, velika tuča rijetka je pojava (Punge i Kunz, 2016.). Prema izvješću ESWD-a najveća tuča zabilježena u Njemačkoj imala je promjer od 141 mm. U istočnom dijelu središnje Europe, koja uključuje Poljsku, Češku, Slovačku i Mađarsku, frekvencija snažnih nevremena s tučom najviša je na jugu, gdje se konvektivna aktivnost povećava zbog orografije (Punge *et al.*, 2014.). To se posebice odnosi na Poljsku gdje utjecaj hlađenja uzrokovan Baltičkim morem smanjuje rizik od snažnih oluja na sjeveru tijekom ljeta. U razdoblju od 16 godina između 1960. i 1978. tuče su bile najučestalije u južnim pokrajinama (Kolkowska i Lorenc, 2012.). Prema dostupnim podacima Češka je jače izložena tuči od Poljske, a frekvencija tuče uglavnom slijedi orografiju (Punge i Kunz, 2016.). U usporedbi s Češkom, Slovačka je znatno manje izložena riziku od tuče, dok je u Mađarskoj u razdoblju između 2004. i 2012. godine zabilježeno prosječno 42 dana u godini s ekstremno jakim olujama i s velikom vjerojatnošću tuče.



Slika 5: Karta Europe s kompozitom događaja tuče iz različitih istraživanja (izvor: Punge i Kunz, 2016.)

Klima u **južnoj Europi** pod jakim je utjecajem visoke insolacije i blizine Sredozemnog mora gdje su tople i vlažne zračne mase advektirane od juga prema zapadu. U sjevernoj su Italiji najčešća snažna nevremena s tučom (Morgan, 1973.; Punge *et al.*, 2014.). Dolina rijeke Po kao i čitav predalpski dio redovito trpi značajne ekonomske štete, uz promjere tuče koji mogu biti veći od 100 mm (Punge i Kunz, 2016.). U predalpskim pokrajinama broj dana s tučom kreće se od oko 30 dana (pokrajina Trentino, ~ 6000 km²) do 55 dana u pokrajini Friuli Veneto Giulia (~ 8000 km²). Najveća učestalost tuče u

razdoblju između 1992. i 2009. godine zabilježena je na području blizu Udina s oko dva dana s tučom po godini, dok je u ostalim dijelovima prosječno zabilježen jedan dan (Manzato, 2012.). Španjolska je također jedna od država s velikim štetama u poljoprivredi uzrokovanim tučom. U razdoblju od 2001. do 2009. godine ona je iznosila oko 240 milijuna eura (Porrás *et al.*, 2013.). U Portugalu je, međutim, velika tuča vrlo rijedak fenomen, pretežno zbog izloženosti Atlantskom oceanu.




Slika 6: Maksimalni prosjek tuče po lokacijama u Europi prema ESWD-u zabilježenog do rujna 2015. godine (izvor: Punge i Kunz, 2016.)

Klima na području **jugoistočne Europe** pod jakim je utjecajem Sredozemlja i Crnog mora na istoku. U Rumunjskoj je najveći promjer tuče izmjeren u Oradei na sjeverozapadu, a iznosi 80 mm (Punge i Kunz, 2016.). Bugarska je izuzetno izložena tuči s prosjekom od 65 dana s tučom po godini. Cjelokupno gledano, štete uzrokovane tučom smanjuju se od zapada prema istoku. Na Balkanskom poluotoku najveća zabilježena tuča promjera je 100 mm (Koceljeva, Srbija, 4. lipnja 2007.). U Hrvatskoj, iz djelomično dostupnih podataka, maksimalni promjer tuče iznosi 80 mm, a zabilježen je na otoku Hvaru (28. kolovoza 2008.). Na području Srbije, na temelju podataka s 28 meteoroloških postaja u razdoblju od 1949. do 2012. godine, učestalost tuče u toplom dijelu godine kreće se od 3,4 na području zapadnih planina do 1,0 na istoku te od 2,0 dana po godini na jugu do 1,0 na sjeveroistoku (Čurić i Janc, 2016.). Na području Sjeverne Makedonije, radarski podaci za razdoblje (1977.-1982.) ukazuju na prosjek od 50 dana s tučom po godini. Za razliku od ostalih zemalja na jugoistoku Europe, tuča nije uobičajen fenomen u Grčkoj, osobito na jugu zemlje. Detaljnija analiza postoji za periferiju Središnje Makedonije gdje je konvektivna aktivnost nešto veća (Punge *et al.*, 2014.). U Turskoj, najveća tuča zabilježena u ESWD-u iznosi 80 mm (9. travnja 2012.).

Na Slici 6 prikazana je distribucija maksimalnih dimenzija zrna tuče, a korišteni su samo podaci iz baze ESWD-a zbog manje pouzdanosti i nedostatka detaljnijih informacija starijih događaja. Važno je otkriće pojava jako velike tuče (veće od 80 mm) u velikom dijelu europskih zemalja. Unatoč mogućoj pristranosti izvješća, jasno je vidljiv maksimum u središnjoj Europi koji se smanjuje prema jugozapadu, sjeveroistoku i jugoistoku.

1.4.2 Istraživanje dostupnih podataka o tuči u Hrvatskoj

U Hrvatskoj se tuča kao meteorološka pojava opaža na standardnim meteorološkim postajama (sinoptičkim i klimatološkim), a mjeri se s pomoću tučomjera, najčešće na lansirnim postajama obrane od tuče postavljenih u Panonskoj nizini (Slika 7). Razlika u opažanjima između standardnih i lansirnih postaja javlja se u količini informacija o intenzitetu i fizičkim obilježjima tuče. Budući da je opažanje tuče prepušteno subjektivnoj procjeni motritelja (za razliku od standardiziranih mjerenja pojedinih meteoroloških veličina), sa standardnih postaja obično su dostupna tri podatka; (i) broj dana s tučom, (ii) opisno procijenjena veličina zrna tuče tijekom usporedbe s dimenzijama drugih poznatih predmeta (npr. grašak, lješnjak, orah, jaje) te (iii) broj zrna koji se opisuje kao *gusta* ili *rijetka* pojava (Počakal, 2012.). Više informacija o obilježjima tuče moguće je dobiti s lansirnih postaja (od 2001. godine u kontinentalnom dijelu) ili poligona (uspostavljenog 2002. godine u Hrvatskom zagorju), Slika 7. Kako su lansirne postaje smještene dominantno u području između rijeka Mure, Save i Drave, detaljnije su analize tuče rađene uglavnom za panonski dio Hrvatske (npr. Gajić-Čapka i Zaninović, 1993.; Počakal, 2012.; Mikuš Jurković *et al.*, 2015.; Kuraži i Počakal, 2016.) dok je obalni dio slabo istraživan (Paškvan, 1955.).



Slika 7: Zemljopisna karta središnje i sjeverozapadne Hrvatske s označenim tučomjerima (točke) na lansirnim postajama i poligonu (žuto) (izvor:

<https://www.google.com/maps/d/viewer?hl=hr&ll=45.6754986377023%2C17.3867477500004&z=8&mid=18R-ST9fAS-tcFbEsAFM35NEzm SZ7Cve>)

Analize su pokazale da su najčešći i najintenzivniji slučajevi tuče na dijelu između Mure, Save i Drave zabilježeni u lipnju (Počakal, 2012.) kada je i konvektivna aktivnost najizraženija (Mikuš *et al.*, 2012.) te KE zrna tuče najveća (Počakal, 2012.). Za analizirano razdoblje 1981.-2009., srednji promjer zrna na području Hrvatske iznosio je 8.1 mm, a najveće izmjereno zrno od 34.5 mm zabilježeno je u istočnoj Slavoniji (Počakal, 2012.). Srednja KE u Hrvatskoj iznosi 36.0 J/m², a najveće srednje mjesečne vrijednosti zabilježene su u lipnju 45.7 J/m². Statistička analiza trenda prosječne dužine padanja tuče tijekom toplog dijela godine za razdoblje od 1981. do 2009. godine potvrdila je da se radi o trendu porasta koji je statistički značajan. Prosječna dužina padanja tuče u Hrvatskoj iznosila je 4.2 min.

U novijem razdoblju (2002.-2015.) za sjeverozapadni dio Hrvatske, analiza promjera zrna tuče pokazala je raspon intervala od 5.0-15.0 mm koji pokriva 95.7% svih mjerenih zrna (Kuraži i Počakal, 2016.). Zabilježen je i negativni trend zrna tuče najmanjeg promjera (5.0-7.5 mm) i pozitivni trend zrna većeg promjera 7.6-15.0 mm, moguće kao posljedica većih ili/i jačih uzlaznih struja i intenzivnijih grmljavinskih ćelija.

Iako su analize podataka tuče uz jadransku obalu vrlo rijetke, provedena analiza za Istru (za sredinu prošlog stoljeća; 1951.-1953.) pokazala je neke dijelove Istre koji imaju učestalije zabilježenu tuču (Paškvan, 1955.). Dok je tuča na zapadnoj obali i središnjim dijelovima Istre češća pojava (posebno linija Poreč-Pazin-Buje), utjecaj planinskog lanca na istočnoj obali umanjuje povoljne uvjete za pojavu tuče. U studiji se povezuje pojava tuče sa smjerom prevladavajućeg vjetrova, te autor ističe dominaciju vjetrova zapadnih smjerova (od SW prema NW) u danima s tučom. Ipak, analize tuče nisu rađene na drugim postajama duž jadranske obale, iako su analize dana s grmljavinom (Penzar *et al.*, 2001.) odnosno munja (Mikuš *et al.*, 2012.) ukazale na neke potencijalno vrlo konvektivno-aktivne lokacije kao što su to Ravni kotari i šire područje Dubrovnika.

1.5 Motivacija i cilj rada

Prethodno poglavlje kao i Slika 5 pokazuju neujednačenost analiza podataka o tuči nad područjem Hrvatske. Iako su subjektivno procijenjeni podaci dostupni za čitavu Hrvatsku, mjereni podaci o tuči uglavnom se dobivaju na lansirnim/radarskim postajama u sklopu obrane od tuče iz ravničarsko-nizinskog dijela. Dosadašnje su analize pokazale da je u dijelovima zapadne i središnje Hrvatske učestalost pojave konvektivne aktivnosti (Mikuš *et al.*, 2012.) i tuče (Počakal, 2012.) velika i visokog je intenziteta, a većina takvih događaja opažena je u blizini izoliranih zapadnih planina (Počakal *et al.*, 2018.). Ipak postoji manjak informacija o obilježjima tuče na drugim dijelovima Hrvatske, što je motiviralo ovo istraživanje. Ovaj manjak mogao bi se upotpuniti primjenom numeričkog modela visoke razlučivosti. Budući da je odnedavno dostupan algoritam za simulaciju tuče u numeričkim modelima pod imenom HAILCAST (npr. Brimelow *et al.*, 2002.; Adams-Selin i Ziegler, 2016.), cilj je provesti numeričke simulacije odabranih slučajeva i evaluirati ih s pomoću postojećih mjerenja. Ovaj algoritam bi trebao omogućiti poboljšanu numeričku prognozu ekstremnog vremena, jer se dosadašnja praksa prognoze tuče provodila preko drugih (indirektnih) konvektivnih parametara. Stoga su


ovdje odabrana dva događaja tuče te su simulirana numeričkim modelom WRF (eng. *Weather Research and Forecasting*). U radu se ispituju (i) procesi koji dovode do rasta zrna tuče odnosno (ii) uspješnost modeliranja tuče u modelu čime bi se pružile daljnje smjernice u podešavanju modela i time pospješila buduća analiza i prognoza tuče.

2 Podaci i metode

2.1 Geografski i klimatološki opis domene

Hrvatska ima kompleksan teren koji se može u grubo podijeliti u tri osnovne cjeline: (i) nizinsko-ravničarski dio koji je odijeljen od (ii) primorskog obalnog dijela (iii) središnjim planinskim lancima uglavnom iznad 600 m nadmorske visine (Slika 8). Gorja u Panonskoj nizini su relativno niska (samo Medvednica, Ivančica i Žumberačka gora prelaze 1000 m). Na njih se nastavljaju prigorja raščlanjena potočnim dolinama, koja se postupno spuštaju u doline većih rijeka (Bednja, Krapina, Glina, Sava i dr.). Najveći prostor zauzima zavala između Medvednice, Žumberačke gore, Kalničkog gorja, Bilogore, Papuka, Psunja, Zrinske gore i Petrove gore, s ravnica uz Savu, Kupu, Lonju, Česmu i Ilovu. U sjevernom dijelu prostor je brežuljkasto-dolinskog karaktera (Hrvatsko zagorje), brežuljkastog karaktera (zapadno Međimurje) te nizine uz Dravu i Muru. Južno od Kupe prevladavaju zaravni i niska vapnenačka pobrđa u porječjima Korane, Mrežnice i Dobre koja sežu do planinskog područja Like. Obala je vrlo kompleksna s brojnim otocima, njih više od 1200.

U klimatološkom smislu, područje sjeverno od planinskog lanca (Dinarida) ima umjereno kontinentalnu klimu s relativno toplim ljetima (sa srednjom dnevnom temperaturom u srpnju od 22 °C) i relativno hladnim zimama (sa srednjom dnevnom temperaturom u siječnju -3 °C; Zaninović *et al.*, 2008). Kontinentalne karakteristike klime u nizini povećavaju se prema istoku. Stanje atmosfere je prilično promjenjivo u proljeće (posebno u travnju) i jesen zbog jakog ciklonalnog djelovanja. Obalno područje ima maritimnu klimu čije karakteristike postaju izraženije prema jugu. Glavne karakteristike su suha i topla ljeta, s maksimalnom srednjom mjesečnom temperaturom u kolovozu. Najveća količina oborine zabilježena je u kasnu jesen.



Slika 8: Prikaz geografskih obilježja istraživanog područja. Crni kvadrat (d2) prikazuje ugniježdenu domenu korištenu prilikom numeričkih simulacija modela WRF. Najveća domena (d1) razlučuje područje s mrežnim korakom od 9 km, a domena korištena u analizi (d2) s 3 km

2.2 Mjerne postaje i podaci

U ovom su radu korišteni podaci prizemnog tlaka (p , hPa), smjera i brzine vjetra (V , m/s), temperature T (°C) i relativne vlažnosti rh (%), s 15 prizemnih postaja Karlovac, Krapina, Križevci, Ogulin, Parg, Pazin, Rab, Rijeka, Senj, Zavižan, Zagreb – Grič, Zagreb – Maksimir, Mali Lošinj, zračnih luka Zagreb i Pula te radiosondažni podaci postaja Zagreb – Maksimir, Zadar, San Pietro i Udine. Radiosondažni podaci preuzeti su sa stranice <http://weather.uwyo.edu/upperair/sounding.html>. Korišteni su i podaci promjera tuče zabilježenih na prostoru središnje i sjeverozapadne Hrvatske s lansirnih postaja ili poligona (Slika 7). Temperatura (T) i relativna vlažnost (rh) mjere se na visini od dva metra, a vjetar na visini od deset metara. Za navedene postaje korištene su srednje satne brzine vjetra (izvorni podaci 10-minutni), a za zračne luke izvještaji METAR. Mjerenja s postaja zapisana su u obliku srednjoeuropskog vremena (eng. *Central European Time*, CET=UTC+1h) te su prebačena u UTC (eng. *Coordinated Universal Time*) kod usporedbe s modelom. Nadalje, za prikaz maksimalnog radarskog odraza korišten je produkt ARSO radara Lisca/Pasja Ravan (<https://www.arso.gov.si/>) koji ažurira sliku svakih 10 minuta. Također, korišteni su i LINET podaci (Betz *et al.*, 2009.) za detekciju munja pri rezoluciji 1x1 km. Korištena skala predstavlja broj udara na pojedinom kvadratiću zabilježen u petominutnom intervalu.

2.3 Računanje relativne vlažnosti rh

Rh predstavlja omjer parcijalnog tlaka vodene pare (e [hPa]) i parcijalnog tlaka zasićene vodene pare (e_s [hPa]):

$$rh = 100 \frac{e}{e_s},$$

koji su dani sljedećim izrazima:

$$e = \frac{p \cdot r}{0.6225 + r} \quad ; \quad e_s = e_{s0} \cdot \exp \left[-\frac{l_v}{R_v} \left(\frac{1}{T} - \frac{1}{T_0} \right) \right].$$

Značenje pojedinog izraza: r je omjer miješanja vodene pare (eng. *water vapour mixing ratio*), $e_{s0} = 6.11$ hPa tlak zasićene vodene pare, $l_v = 2.5 \cdot 10^6$ J/(kg·K) latentna toplota isparavanja i $R_v = 461.5$ J/(kg·K) plinska konstanta vodene pare.

Rezultati modela (označeno indeksom m) ne daju ispis vrijednosti rh . Stoga ih je potrebno proračunati te se u izvodu koriste modelirani podaci prognoziraniog tlaka (p_m), omjera miješanja vodene pare (r_m) i temperature T_m . Postupak se sastoji od nekoliko koraka:

- (1) određivanje parcijalnog tlaka vodene pare (e) iz modeliranih polja tlaka i omjera miješanja (p_m, r_m)
- (2) određivanje parcijalnog tlaka zasićene vodene pare (e_s) iz modeliranog polja temperature (T_m)
- (3) računanje rh kao omjer e i e_s .

Podaci prizemnih i radiosondažnih postaja u sebi sadrže informaciju o rh . Iznimka su

podaci zračnih luka u kojem se provodi prethodno navedeni račun uz razliku da se parcijalni tlak vodene pare e računa prema jednadžbi

$$e = e_{s0} \cdot \exp \left[-\frac{l_v}{R_v} \left(\frac{1}{T_{ds}} - \frac{1}{T_0} \right) \right],$$

budući da je dostupan podatak o temperaturi rosišta T_{ds} . Račun i grafički prikazi izrađeni su s pomoću programskog paketa *Matlab*.

2.4 Odabrani slučajevi

Za analizu i evaluaciju modela su odabrane dvije epizode sa zabilježenom tučom na području središnje i sjeverozapadne Hrvatske. Razlog odabira tih epizoda jest zabilježena tuča na većem broju tučomjera na posebno dizajniranom poligonu te na lansirnim postajama. Za prvi odabrani slučaj u kojem analiziramo vremensko razdoblje od 30. do 31. srpnja 2014. godine, tuča je zabilježena prvog dana poslijepodne između 14 i 17 sati prema UTC-u. U drugoj odabranoj epizodi analiziramo vremensko razdoblje od 16. do 17. rujna 2017. godine, a tuča je zabilježena u večernjim i noćnim satima, odnosno od 19:00 UTC prvoga dana do 01:00 UTC noći drugoga dana.

2.5 Model WRF i WRF-HAILCAST

Model WRF mezoskalni je numerički model namijenjen istraživanju i prognozi vremena. Postoje dvije glavne verzije, odnosno jezgre modela. Prva je istraživačka verzija modela WRF-ARW V3 (eng. *Advanced Research WRF, Verzija 3*) koja omogućuje visoku vremensku i prostornu razlučivost te velik broj (i odabir) parametrizacija. Stoga se uglavnom koristi u istraživanjima. Druga je inačica WRF-NMM (eng. *Nonhydrostatic Mesoscale Model*), a koristi se u svrhu svakodnevne prognoze vremena. Ovoj odabranoj istraživačkoj verziji modela pridodana je opcija simuliranja zrna tuče tzv. HAILCAST model (1-D model koji prognozira veličinu tuče koja padne na tlo). HAILCAST se bazira na promijenjenoj verziji modela oblaka i tuče koji je razvio Poolman (1992.), a unaprijedili Brimelow *et al.* (2002.), Jewell i Brimelow (2009.) te Adams-Selin i Ziegler (2016.).

2.5.1 Opće karakteristike i postavke modela WRF

Simulacija je izvedena u Lambertovoj stožastoj projekciji na razmaknutoj Arakawa C mreži uz pomoć jednosmjerno ugniježđenim domenama (Slika 8) na 66 vertikalnih razina koje prate teren. Najniža razina je oko 22 metara iznad tla. Najveća domena d1 obuhvaća Apeninski i Balkanski poluotok, Panonsku nizinu te planinske lance Alpski masiv i Karpate. Mrežni prostorni korak najveće domene iznosi 9 km (uz 204 x 180 točaka) dok je vremenski korak integracije 40 s. Domena d2 je fokusirana na cijelu Hrvatsku te ju razlučuje s 3 km u prostoru i 235 x 214 točaka. To je ujedno i domena iz koje su analizirani rezultati numeričkog modela.

Početni i rubni uvjeti preuzeti su iz centra *ECMWF* (eng. *European Centre for Medium-range Weather Forecasts*) na standardnim izobarnim plohama svakih 6 sati. Vremensko trajanje simulacija je 30 h sa zapisom rezultata modela od 1 h. Topografija i kategorije karakteristika površine (eng. *land cover*) preuzete su iz GMTED (eng. *Global Multi-resolution Terrain Elevation Data*) i MODIS (eng. *Moderate Resolution Imaging Spectroradiometer*) baze podataka rezolucije od 30".

Za vremensku integraciju koristi se Runge-Kutta shema trećeg reda točnosti koja dijeli osnovni vremenski korak na manje dijelove s ciljem uklanjanja zvučnih valova i boljom prezentacijom težinskih valova. WRF nudi razne sheme u smislu postavki parametrizacija i numeričkih opcija unutar samog modela. Za planetarni granični sloj korištena je shema Mellor-Yamada Nakanishija i Niina (MYNN 2.5) koja predviđa subćelijske uvjete turbulentne kinetičke energije. Odabir sheme za atmosferski granični sloj povlači korištenje shema MYNN2 za površinski sloj te shemu *Noah Land Surface Model* za kopnenu površinu koja razlučuje temperaturu i vlagu u tlu s četiri sloja, djelomični pokrivač snijega i fizičke procese zamrznutog tla. Za dugovalno zračenje se koristi RRTM (eng. *Rapid radiative transfer model*) te za kratkovalno zračenje shema koju je predložio Dudhia (Dudhia, 1989.). Za mikrofizička obilježja oblaka je odabrana shema koju je predložio Morrison (Morrison *et al.*, 2009.). Ona uključuje šest oblika oblačnih elemenata: vodene kapljice u oblaku, kristaliće leda u oblaku, kišu, vodenu paru, snježne pahuljice, dvije vrste krute oborine (eng. *graupel and hail*). Kumulusna parametrizacija prema prijedlogu koji su dali Kain i Fritsch (1993.) koristi se samo u najvećoj domeni, d1.

2.5.2 Izvorni HAILCAST model

HAILCAST je jednodimenzionalni stacionarni model oblaka spojen s vremenski ovisnim modelom razvoja tuče (npr. Brimelow *et al.*, 2002.; Jewell i Brimelow, 2009.). Profili temperature, vlage i horizontalnog vjetra koriste se u proračunu za dobivanje vertikalnih profila vertikalne brzine, tekućeg vodenog sadržaja i leda te temperature koju povezujemo s oblakom. HAILCAST model uvažava proces uvlačenja vodenog sadržaja (eng. *water loading*) pri uzlaznom strujanju. Model polazi od pretpostavke da su početni profili atmosferskih varijabli (temperature, vlage i horizontalnog vjetra) u ravnotežnom stanju (stacionarni). Brimelow *et al.* (2002.) su definirali ograničeno trajanja uzlaznog gibanja zraka. Ono se bazira na ESI (eng. *energy shear index*), indeksu koji se temelji na vrijednostima konvektivne raspoložive potencijalne energije (eng. *Convective Available Potential Energy, CAPE*) i na smicanju vjetra u području između 850 hPa i 6 km iznad tla. Veća vrijednost indeksa omogućuje dulje trajanje uzlaznog strujanja. Model rasta tuče ubacuje vodeni embrio u bazu oblaka. Embriju je dana početna brzina od 4 m/s i u svakom vremenskom koraku izračunata je njegova vertikalna pozicija na temelju njegove konačne brzine i interpolirane brzine uzlaznog strujanja za tu visinu. Penjući se na veće visine embrio akumulira tekuću vodu. Iznad -8 °C automatski se zamrzne. Sama tuča definirana je kao sferna ledena čestica. Zrno tuče ulazi u vlažan ili suh režim ovisno o svojoj unutarnjoj temperaturi i temperaturi unutar oblaka. Kada zrno tuče naraste do mjere da ga uzlazno strujanje ne može zadržati na određenoj visini ili kad uzlaznog

strujanja više nema, ono se počne spuštati. Konačna brzina padanja zrna tuče računa se prema Rasmussen i Heymsfield (1987.) metodi. Kada se spusti ispod visine baze oblaka, profil vlage oblaka postavljen je na vrijednost 0. Uz ravnotežno stanje uzlaznog strujanja, glavne pretpostavke modela su konstantna gustoća leda (900 kg m^{-3}), sferični oblik zrna tuče te početni dijametar embrija od $300 \text{ }\mu\text{m}$. Također, led u oblaku postoji na temperaturama od $-20 \text{ }^{\circ}\text{C}$ do $-40 \text{ }^{\circ}\text{C}$, a njegova količina određena je eksponencijalnom relacijom (Vali i Stansbury, 1965.).

2.5.3 Implementacija HAILCAST modela u WRF model


Jedna od najbitnijih pretpostavki napravljenih u HAILCAST-u (npr. Jewell i Brimelow, 2009.; Adams-Selin i Ziegler, 2016.) jest korištenje *cloud* modela za simulaciju uzlaznog strujanja zraka u oluji (Slika 9). Model WRF s razlučivošću od 4 km ili manjom reproducira cirkulaciju veće skale i hidrometeorološka polja koja povezujemo s organiziranim olujama i konvektivnim sustavima. Idealno bi bilo tjerati vremensko-ovisni model tuče unutar samog WRF-a, što bi dopustilo embriju da se kreće u tri dimenzije kroz oluju. Alternativno, kao u WRF-HAILCAST modelu, vertikalno strujanje zraka, vodeni tekući i ledeni sadržaj te temperaturni profili iz WRF u određenom vremenskom koraku se prenose u WRF-HAILCAST modelu tuče. Embriji su ubačeni na mjesto uzlaznog strujanja zraka i praćeni kako se dižu, rastu i padaju. Prognozirani podatak o tuči se prenosi natrag u model WRF i prelazi na novi vremenski korak. Jedina informacija koju WRF-HAILCAST vrati u model WRF je veličina tuče na tlu. Ledeni sadržaj određen je korištenjem omjera miješanja leda i snijega u oblaku iz modela WRF. Pokazalo se da profil omjera miješanja vode u oblaku iz WRF-a daje neadekvatnu reprezentaciju superohlađene vode dostupne za rast tuče sudarom kristala leda i superohlađene vode (jer je već iskorišten sudarima sa solikom i spontanom prijelazom u kišu unutar mikrofizičke parametrizacije). Rast tuče sudarima s česticama oborine (solika ili kiša) u WRF-HAILCAST-u je zanemaren. Iako dolazi do takvih sudara, oni su rijetki zbog male koncentracije naspram čestica oblaka. Ako dođe do sudara, vjerojatno će čestica solike odskočiti od tuče. Omjer miješanja snijega nije izuzet zbog teškoća u određivanju prelaska leda u oblaku u snijeg unutar WRF mikrofizičke parametrizacije (Morrison i Milbrandt, 2015.).

Za približno simuliranje horizontalnog gibanja embrija relativno u odnosu na uzlazno strujanje zraka u lagrangianskom smislu (prateći česticu) koristi se vremensko ovisni množitelj oblika:

$$W_{hail}(z, \tau) = \begin{cases} \left[0.6 \sin\left(\frac{\pi \tau}{W_{dur}}\right) + 0.6 \right] W(z) & \text{if } \tau \leq W_{dur} \\ 0 & \text{if } \tau > W_{dur} \end{cases}$$

kako bi za zrno tuče izračunala relativna brzina strujanja zraka za svaku razinu z u svakom WRF-HAILCAST vremenskom koraku. Značenje pojedinog izraza: τ – vremenski korak WRF-HAILCAST-a, W_{hail} – brzina uzdizanja zraka koji dolazi u kontakt sa zrnom tuče, $W(z)$ – profil uzdizanja zraka iz WRF-a, W_{dur} – ograničenje trajanja uzdizanja zraka.

Odabir sinusoidnog člana osigurava početno slabije uzdizanje zraka kako bi se omogućio rast ranom embriju. Unutar modela WRF, radi određivanja W_{dur} uvedena je nova dijagnostička veličina $WDUR$. Za svaki vremenski korak uspoređuje se polje uzdizanja zraka prethodnog i trenutnog vremenskog koraka. Ako u tim vremenima u određenoj ćeliji ili u pokrajnjoj ćeliji maksimalna brzina uzdizanja zraka prelazi 10 m/s, trajanje uzdizanja zraka uvećava se za jedan WRF vremenski korak. To nam omogućuje praćenje zrna u uzlaznim strujama i njihovo trajanje unutar pojedinih ćelija mreže modela. Trajanje uzdizanja zraka u vremenu od 3-4 sata uobičajeno je s obzirom na to da algoritam prati dugo-živuće superćelijske i mezoskalne konvektivne sustave. Međutim, fizikalno nije realno da tuča tako dugo ostane u području uzdizanja zraka pa je maksimalno trajanje W_{dur} ograničeno na 2000 s unutar WRF-HAILCAST-a. To potvrđuju studije iz kojih proizlazi da je životni vijek uzdizanja zraka i rasta tuče u multićelijskim i superćelijskim olujama do 30 minuta (Adams-Selin i Ziegler, 2016.).




Slika 9: Konceptualni model obrade podataka unutar WRF-HAILCAST-a (izvor: Adams-Selin i Ziegler, 2016.)

Za svaki WRF vremenski korak unutar ćelije koja sadrži uzdizanje zraka brzine 10 m/s ili više, uzdizanje zraka mora trajati barem 15 minuta (polje mora postojati barem 15 minuta iako ne mora cijelo to vrijeme biti u istoj ćeliji). Ako su zadovoljeni ti uvjeti, profili vertikalne brzine, temperature te omjeri miješanja vode, leda i snijega u oblaku iz te se ćelije prebacuju u WRF-HAILCAST model tuče. Pet se embrija ubacuje na temperaturama -8 °C i 13 °C. Temperature su odabrane tako da se slažu s lokalnim početnim radarskim odzivima (npr. Foote i Wade, 1982.), kao i sa zaključkom da za taj interval temperatura dolazi do česte pojave tuče (Heymsfield *et al.*, 1980.). Profili temperature, vodenog i ledenog sadržaja u oblaku smatraju se stacionarnim u odnosu na rast zrna tuče sve dok nije dosegnut W_{dur} . Tada se uzima da je tuča izašla iz oblaka, brzina uzdizanja zraka stavljena je na nulu, kao i profili vodenog i ledenog sadržaja. Kada tuča određene veličine dosegne tlo, njezin se promjer vraća u WRF. Tada se WRF pomiče za sljedeći vremenski korak i ponavlja opisan proces te dobivamo novu prognozu. WRF

sprema maksimalni promjer tuče vraćen iz WRF-HAILCAST-a za svaku ćeliju mreže. Čitav opisani proces ponavlja se sve dok na čitavoj mreži postoji uzdizanje zraka brzine ≥ 10 m/s te *WDUR* traje najmanje 15 minuta. Testiranja WRF-HAILCAST-a su potvrdila osjetljivost prognoziranog promjera tuče u odnosu na početnu temperaturu i veličinu embrija. Izlazni parametri WRF-HAILCAST-a su maksimum, srednjak i standardna devijacija promjera tuče za prijašnjih pet embrija.

2.5.4 Modifikacije WRF-HAILCAST modela

U WRF-HAILCAST-u gustoća zamrznute tuče varira. Početna vrijednost određena je na 500 kg/m^3 . Ako rastuće zrno tuče naknadno uđe u mokar režim, sva nezaleđena voda smatra se upijenom u tuču ako je njezina gustoća manja od 900 kg/m^3 . Pretpostavljena gustoća sloja leda koji se stvara prilikom mokrog režima iznosi 900 kg/m^3 .



Slika 10: Originalna (crtkana) i modificirana (puna linija) funkcija efikasnosti sakupljanja leda (izvor: Adams-Selin i Ziegler, 2016.)

Prvotno je efikasnost sakupljanja leda u HAILCAST modelu tuče bilo prikazano skokovito; funkcija efikasnosti je jednaka 1 ako je temperatura okoliša viša od -5 °C i jednaka 0.21 za niže temperature, Slika 10. Ovdje je ona zamijenjena linearnom funkcijom koja varira od 1 na T od 0 °C do 0 na T od -40 °C . Uslijed toga povećana je mogućnost „lijepljenja” čestice leda na zrno tuče kod toplije temperature, osobito ako zrno ima vodeni sloj na površini. Efikasnost sudara i sakupljanja tekuće vode iznosi 1 za sve temperature. Model u procesima omogućuje izbacivanje viška vode sa zrna tuče. Stoga, samo je tanki sloj tekuće vode moguć na zrnu tuče prilikom mokrih režima i topljenja. Također, WRF-HAILCAST sada sadrži povećanu brzinu topljenja kad se zrno tuče sudara s tekućom vodom ispod razine zaleđivanja.

2.5.5 Statistički parametri korišteni u evaluaciji modela

U svrhu procjene pouzdanosti rezultata i određivanja kvalitete modela primijenjene su određene statističke mjere (Tablica 1). U radu su korištene sljedeće statističke mjere: koeficijent korelacije (r), srednja apsolutna pogreška (eng. *Mean Absolute Error, MAE*), korijen srednje kvadratne pogreške (eng. *Root Mean Square Error, RMSE*) i pristranost (eng. *BIAS*). Koeficijent korelacije pokazuje u kojoj su mjeri izmjereni i simulirani podaci linearno zavisni. Model je pouzdaniji što je koeficijent korelacije bliži vrijednosti 1. MAE i $RMSE$ mjere su pogreške modela u odnosu na izmjerene vrijednosti. Općenito manje vrijednosti MAE i $RMSE$ podrazumijevaju bolje slaganje modela i mjerenja (vrijednost 0 znači da model prognozira savršeno). Vrijednosti M i O označuju modelirane i opažene nizove određene meteorološke varijable, M_i i O_i označuju i -te modelirane i opažene vrijednosti, \bar{M} i \bar{O} srednje vrijednosti nizova. σ_M^2 i σ_O^2 su kvadrati standardnih devijacija simuliranih i opaženih nizova. Standardna devijacija je mjera raspršenosti podataka i predstavlja prosječno odstupanje od srednje vrijednosti niza.

Tablica 1: Statistički parametri korišteni u evaluaciji modela


STATISTIČKI PARAMETAR	FORMULA
Srednja apsolutna pogreška (MAE)	$MAE = \frac{1}{N} \sum_{i=1}^N M_i - O_i $
Korijen srednje kvadratne pogreške ($RMSE$)	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (M_i - O_i)^2}$
Pristranost ($BIAS$)	$Bias = \bar{M} - \bar{O}$
Koeficijent korelacije (r)	$r = \frac{1}{N} \frac{\sum_{i=1}^N (M_i - \bar{M})(O_i - \bar{O})}{\sigma_M \sigma_O};$ $\sigma_M^2 = \frac{1}{N} \sum_{i=1}^N (M_i - \bar{M})^2; \sigma_O^2 = \frac{1}{N} \sum_{i=1}^N (O_i - \bar{O})^2$

3 Karakteristike odabranih epizoda i usporedba s modelom

3.1 Karakteristike slučaja 30.-31. srpnja 2014.

Odabrana epizoda obuhvaća vremensko razdoblje od 00:00 UTC 30. srpnja do 06:00 UTC 31. srpnja 2014. godine u kojem model reproducira sinoptičke uvjete koji su pogodovali razvoju jačeg poslijepodnevnog olujnog nevremena nad Hrvatskom. Za promatrano razdoblje korištene su prizemne dijagnostičke karte i kombinirane sinoptičke karte dobivene globalnim meteorološkim modelom (*GFS*) te radiosondažna mjerenja u terminima 12:00 UTC i 00:00 UTC. Nadalje, u analizi su korištene slike maksimalnog radarskog odziva (dBZ) i električnih pražnjenja (*LINET*) u odabranim terminima.

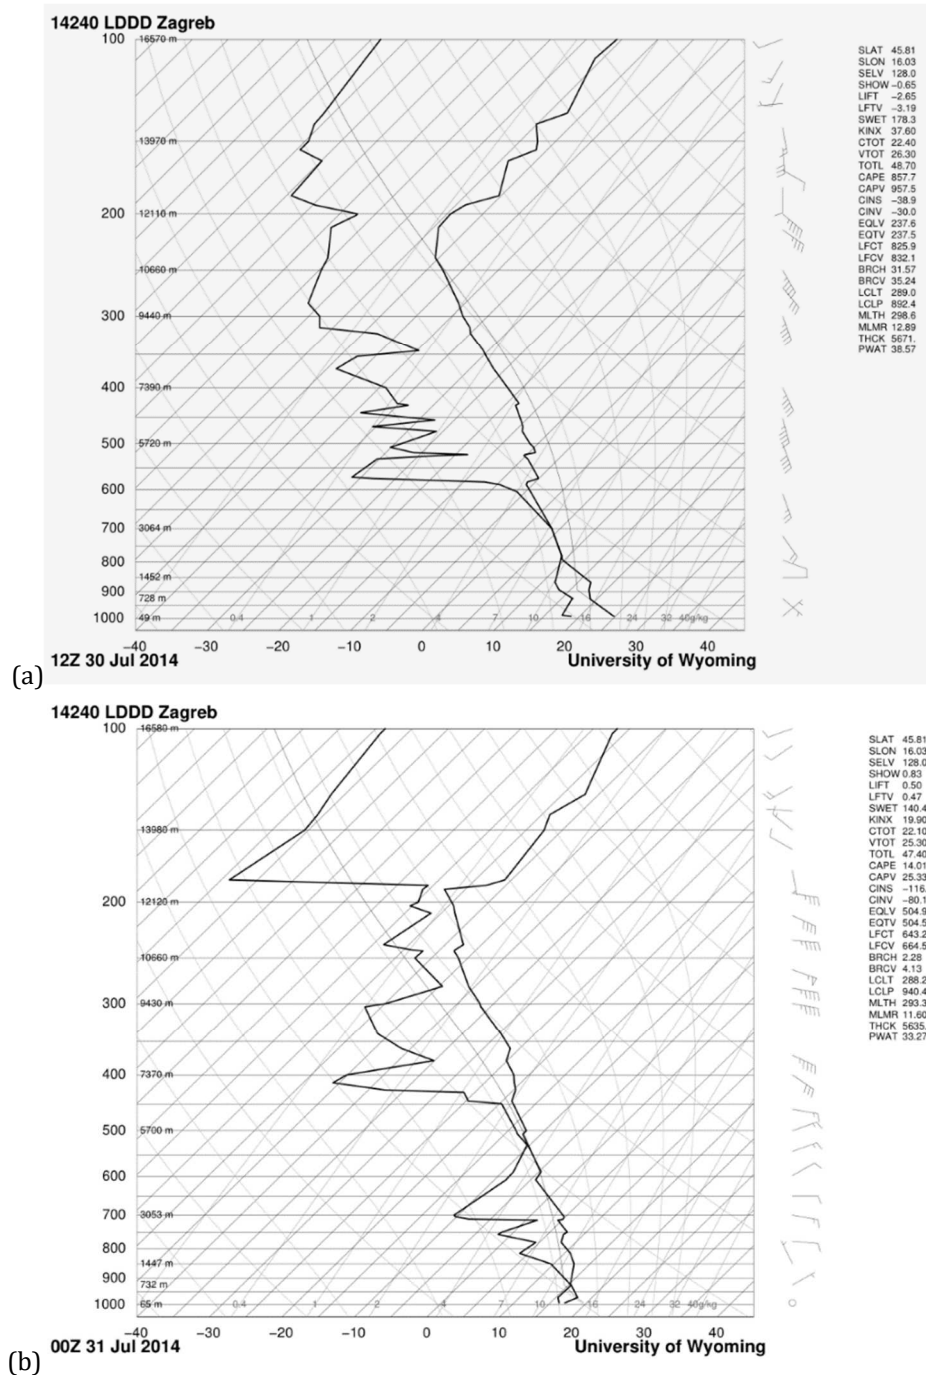
Sliku 11 čine prizemna sinoptička karta Europe (Slika 11a) i kombinirana sinoptička karta (Slika 11b) na kojoj je prikazan geopotencijal na 500 hPa plohi (crne linije), prizemni tlak na razini mora (bijele linije) i relativna topografija RT_{1000}^{500} (boje). Prema raspodjeli baričkih sustava, u 12:00 UTC 30.07.2014., Hrvatska se tog dana nalazila pod utjecajem polja sniženog tlaka zraka koje se formiralo iznad Genovskog zaljeva. Središte ciklone nalazilo se iznad Italije i sjevernog Jadrana, a ciklona je bila u stadiju najveće razvijenosti tj. započet je proces (hladne) okluzije. Spomenuti poremećaj je bio generiran s dubokom dolinom koja se pružala od Skandinavije prema Sredozemlju. Područje interesa nalazio se pod utjecajem prednjeg dijela ciklone te posljedično umjereno do jakog vjetra iz istočnih smjerova (E-SE). U izraženoj jugoistočnoj struji zraka stizao je nad područje Hrvatske nestabilan i vlažan zrak, čime su nastali povoljni uvjeti za pojavu duboke konvekcije.



Slika 11: (a) Prizemna dijagnostička karta Europe i (b) visinska sinoptička karta 30.07.2014. u 12:00 UTC (izvor: <http://www1.wetter3.de/>)

Za isti vremenski termin, na Slici 12, je prikazan vertikalni profil atmosfere nad Zagrebom. Dnevne vrijednosti nekih konvektivnih indeksa kao što su konvektivna raspoloživa potencijalna energija ($CAPE=857 \text{ J kg}^{-1}$), konvektivna inhibicija ($CIN=-38,9 \text{ J/kg}$), indeksa podizanja ($LI=-2,65$) i K -indeksa ($KI=37,60$) upućuju na potencijalno izraženiju konvektivnu aktivnost (<https://www.weather.gov/lmk/indices>) tog dana (Slika 12a). Razina smrzavanja se nalazi na izobarnoj plohi 650 hPa, a male razlike u

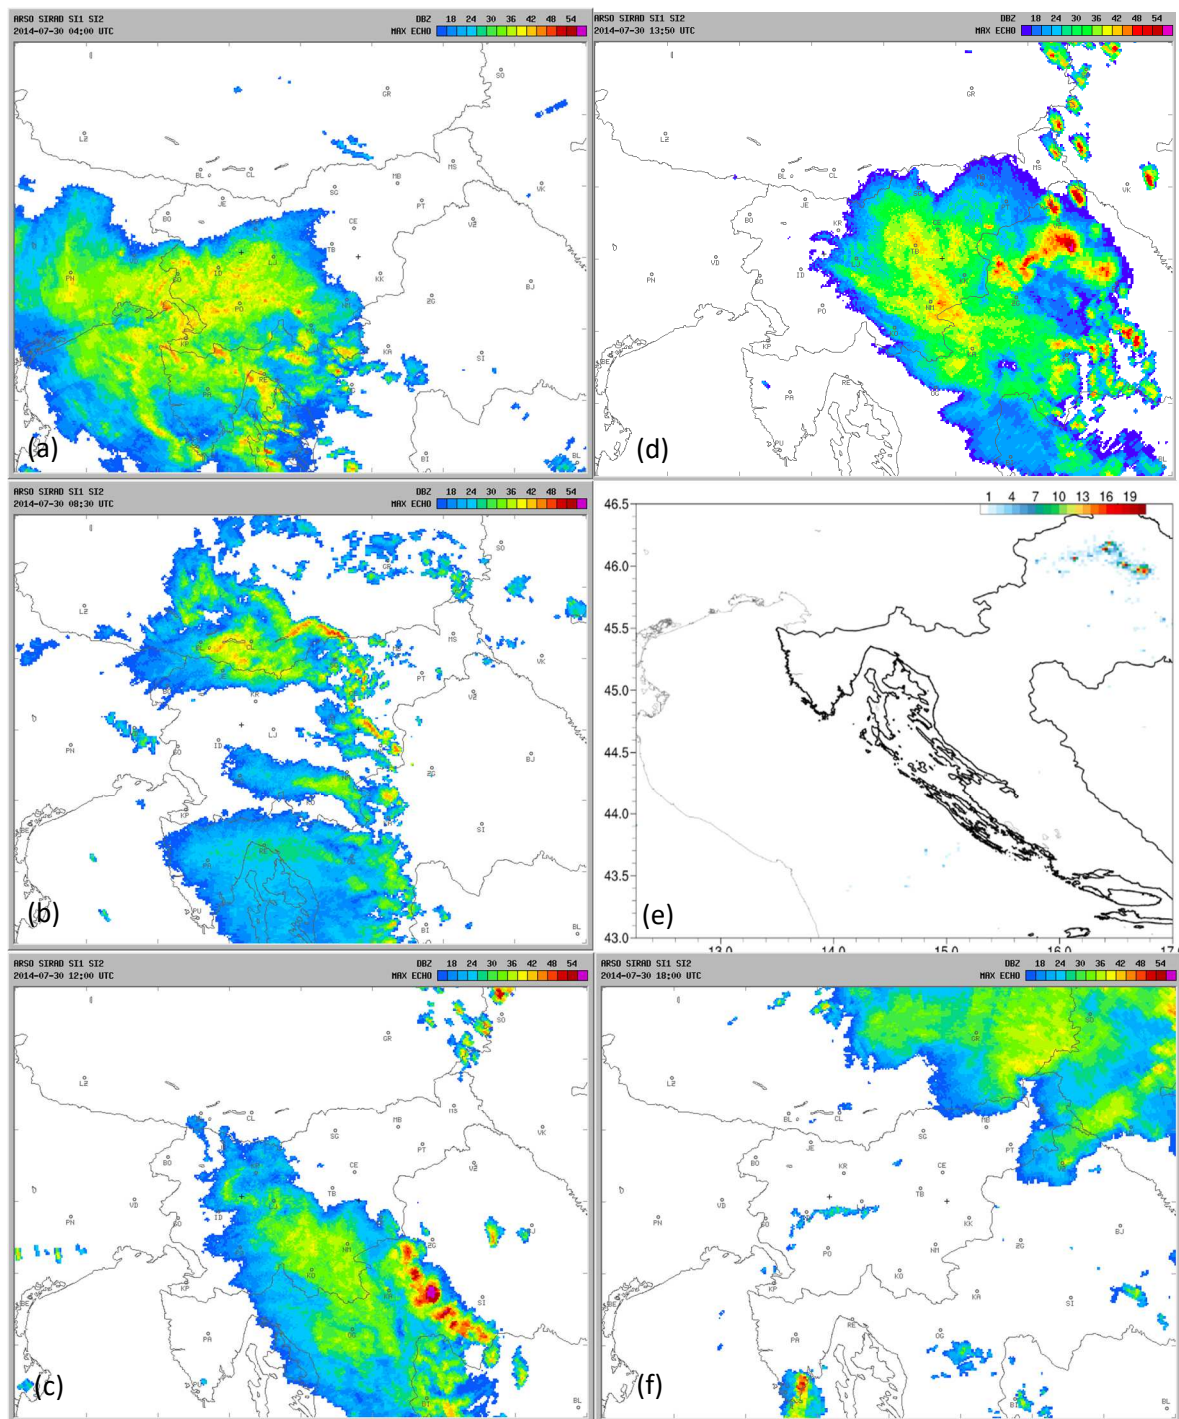
deficitu rosišta ($T-T_d$) na plohi 800 hPa ukazuju na stvaranje oblaka. Jak deficit rosišta započinje iznad plohe 600 hPa. Prevladavajući jugoistočni vjetar slabo mijenja smjer po visini dosežući 23 m/s na 500 hPa plohi te ukazuje na značajno smicanje strujanja u prvih 6 km iznad tla.



Slika 12: Termodinamički dijagram radiosondaže za postaju Zagreb – Maksimir (a) 30.07.2014. u 12:00 UTC i (b) 31.07.2014. u 00:00 UTC (izvor: <http://weather.uwyo.edu/upperair/sounding.html>)

Tijekom dana ciklona se nastavlja premješati u smjeru sjeveroistoka, a 12 sati kasnije, raspodjela tlaka u donjoj troposferi je slična onoj dnevnoj (nije prikazano). Istodobno, u kasnim popodnevnim i noćnim satima fronta okluzije slabi, što je znak

zamiranja ciklalnog vrtloga. Noćni vjetar iz pretežno istočnog smjera nad Zagrebom (slika 12b; 31.07.2014. u 00:00 UTC) također slabi te ne prelazi 10 m/s na 500 hPa plohi,



Slika 13: (a,b,c,d, f) Maksimalan radarski odraz (dBZ) (izvor: <http://www.arso.gov.si>) i (e) broj udara munje (podaci iz LINET baze) za 30.07.2014. u (a) 04:00 UTC, (b) 08:30 UTC, (c) 12:00 UTC, (d) 13:50 UTC i (f) 18:00 UTC. (izvor: <http://www.arso.gov.si>). (e) Broj udara munje (podaci iz LINET baze) za 30.07.2014. u 13:50 UTC

čime se smanjuje i smicanje vjetra u donjem dijelu atmosfere. Noćne vrijednosti nekih od indeksa nestabilnosti u odnosu na 12:00 UTC prethodnog dana su vrlo male, osobito

vrijednost konvektivne raspoložive potencijalne energije ($CAPE$ iznosi 14.01 J/kg) i konvektivne inhibicije ($CIN = -116,17$ J/kg). Nadalje, LI indeks iznosi 0.50, a K indeks 19.90. Razina smrzavanja nalazi se na izobarnoj plohi 650 hPa. Dovoljno mala razlika u deficitu rosišta ($T-T_d$) koja ukazuje da stvaranje oblaka započinje iznad 600 hPa plohe. Navedeni podaci upućuju na to da je riječ o visokim oblacima (cirrusima) i da nema konvektivne aktivnosti.

U ranim jutarnjim satima (04:00 UTC/05:00 CET) maksimalni mjereni radarski odraz (Slika 13a) ukazuje na konvektivnu aktivnost slabijeg intenziteta nad područjem Slovenije, Istre i Kvarnera dok je nad sjeverozapadnim dijelom Hrvatske nema. Premještanje sustava prema istoku se nastavlja u prijepodnevnim satima, Slika 13b, preko područja Slovenije, Gorskog Kotara i Like. U 11:30 UTC je započela pojačana konvektivna aktivnost zapadno od Karlovca (Slika 13c), a završila u 16:20 UTC zapadno od Bjelovara. U vremenskim razdobljima od 12 – 13 UTC i 13:10 – 14:10 UTC konvektivna aktivnost je obilježena najvećim intenzitetom (>54 dBZ; Slike 13c i d), a najveća prostorna pokrivenost nastupa oko 14:00 UTC (Slika 13d). Mjereni radarski odraz potkrepljuju i podaci o broju udaru munja. U 12 UTC zabilježena je prva pojava munja nad promatranim područjem te je razdoblje od 12:20 – 12:50 UTC i 13:40 – 14:10 UTC zabilježen velik broj udara (Slika 13e). Nakon 14:10 UTC nema podataka o munjama. Sustav u večernjim satima odmiče prema Mađarskoj i slabi iznad Hrvatske (Slika 13f). Tada je maksimalni radarski odraz nad analiziranim područjem slab ili ga nema u skladu s prethodno opisanom sinoptičkom situacijom koja ukazuje na sve stabilnije atmosferske uvjete.

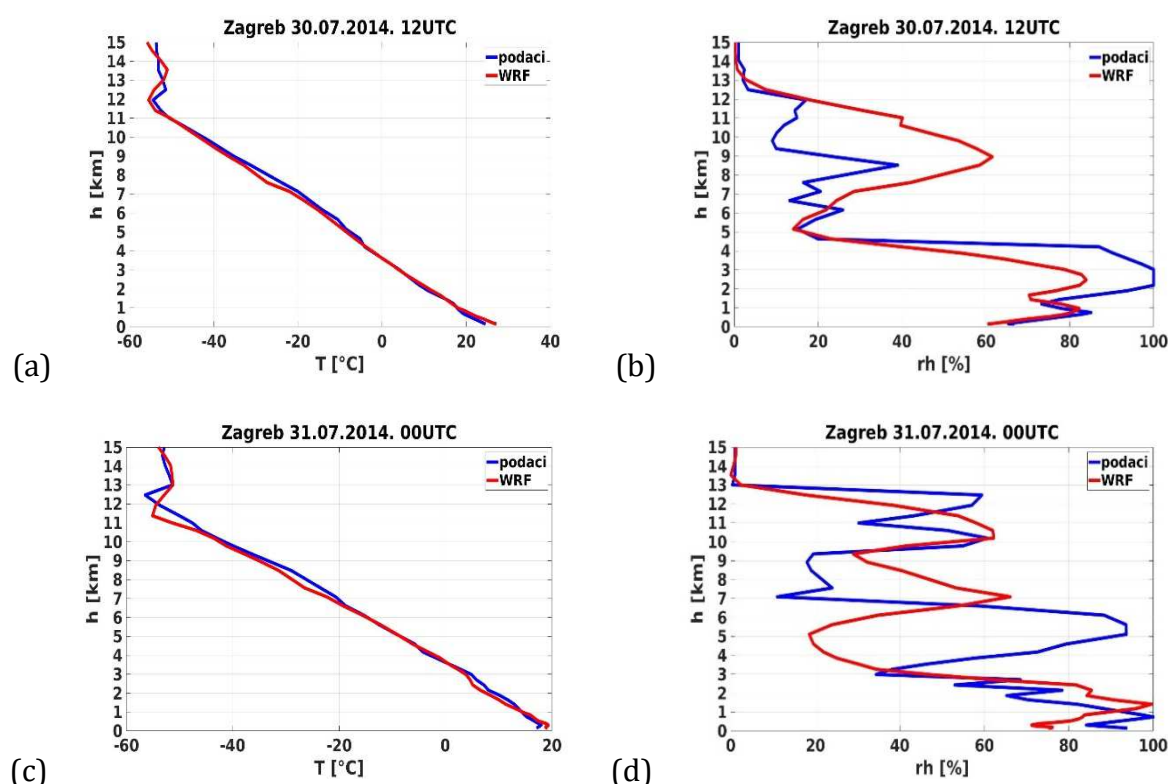
3.2 Analiza rezultata WRF modela za slučaj 30.-31. srpnja 2014.

3.2.1 Evaluacija modela po postajama za slučaj 30.-31. srpnja 2014.

Postojeće radiosondaže, osim što otkrivaju vertikalnu strukturu atmosfere, omogućuju i procjenu uspješnosti numeričkih simulacija. Stoga su na Slici 14 plavom bojom prikazani izmjereni, a crvenom bojom modelirani podnevni vertikalni profili T i rh postaje Zagreb – Maksimir. Tijekom podneva 30.07.2014., model pokazuje dobro slaganje s izmjerenim vrijednostima i postoji veliko podudaranje za oba parametra; ipak više za T i manje za rh (Slike 14a,b). Model je vrlo malo precijenio T u dnevnom prizemnom sloju, što je popraćeno sušim zrakom u najnižem dijelu modeliranog graničnog sloja. Karakteristike preostalog graničnog sloja su vrlo dobro reproducirane numeričkim modelom, što ukazuje na realistično simulirane procese prijenosa topline i vlažnosti turbulentnim tokovima vrlo važnih kod formiranja duboke konvekcije. Pri vrhu i neposredno iznad graničnog sloja (u sloju od 1.5 km do 4 km), unatoč dobro reproduciranoj T , model ponešto podcjenjuje iznos rh .

Vertikalni noćni profili T i rh postaje Zagreb – Maksimir (u 00:00 UTC,) su prikazani na Slikama 14c i 14d. Model je uspješno reproducirao vertikalni profil T pa je podudaranje izmjerenih i modeliranih podataka veliko (Slika 14c). Međutim, u usporedbi s podnevnom situacijom, rh je lošije prognozirana (korelacija je otprilike 20% manja, Slika 14d).

Na Slici 15 prikazane su vrijednosti statističkih parametara korištenih u evaluaciji modela. Statistička evaluacija provedena je na dostupnim podacima triju radiosondažnih postaja Zagreb-Maksimir, Zadar, i San Pietro Capofiume, na prizemnim podacima 13 standardnih postaja u okviru mreže Državnog hidrometeorološkog zavoda te dviju zračnih luka. Na radiosondažnim podacima provedena je usporedba mjerenja po visini, a na prizemnim standardnim postajama uspoređivali su se vremenski nizovi uvažavajući *spin-up time* numeričkog modela. Za potrebe proračuna podaci radiosondaža su se interpolirali na nivoe modela što je omogućilo numeričku usporedbu nizova podataka po visini.

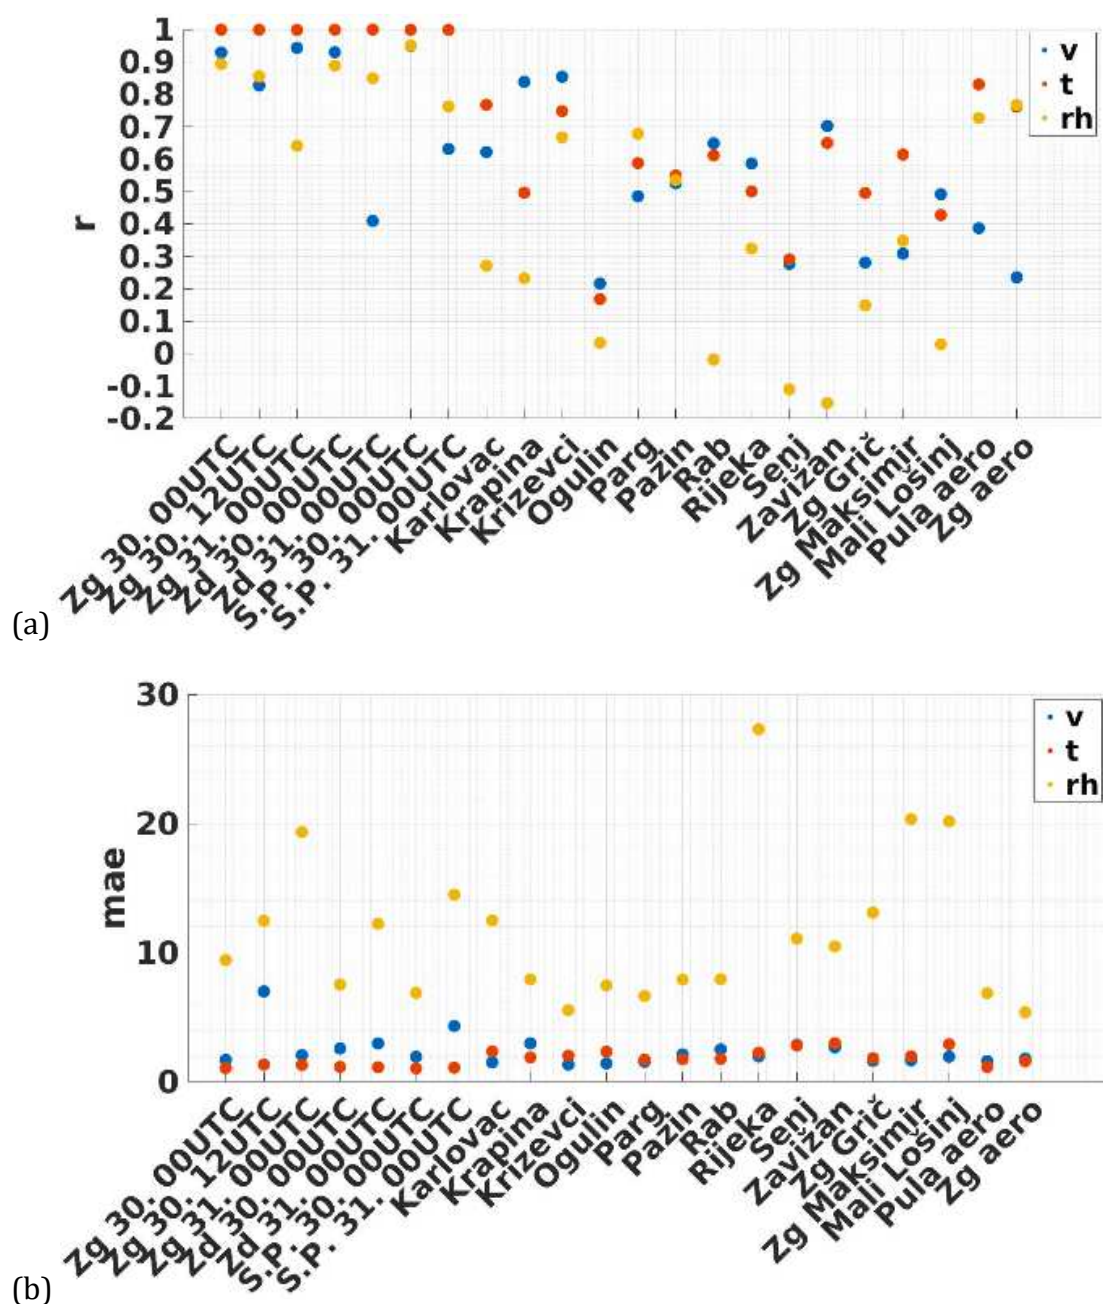


Slika 14: Izmjereni (plavo) i modelirani (crveno) vertikalni profili (a,c) temperature (T , °C) i (b,d) relativne vlažnosti (rh , %) postaje Zagreb – Maksimir za (a,b) 30.07.2014. u 12:00 UTC te (c,d) 31.07.2014. u 00:00 UTC

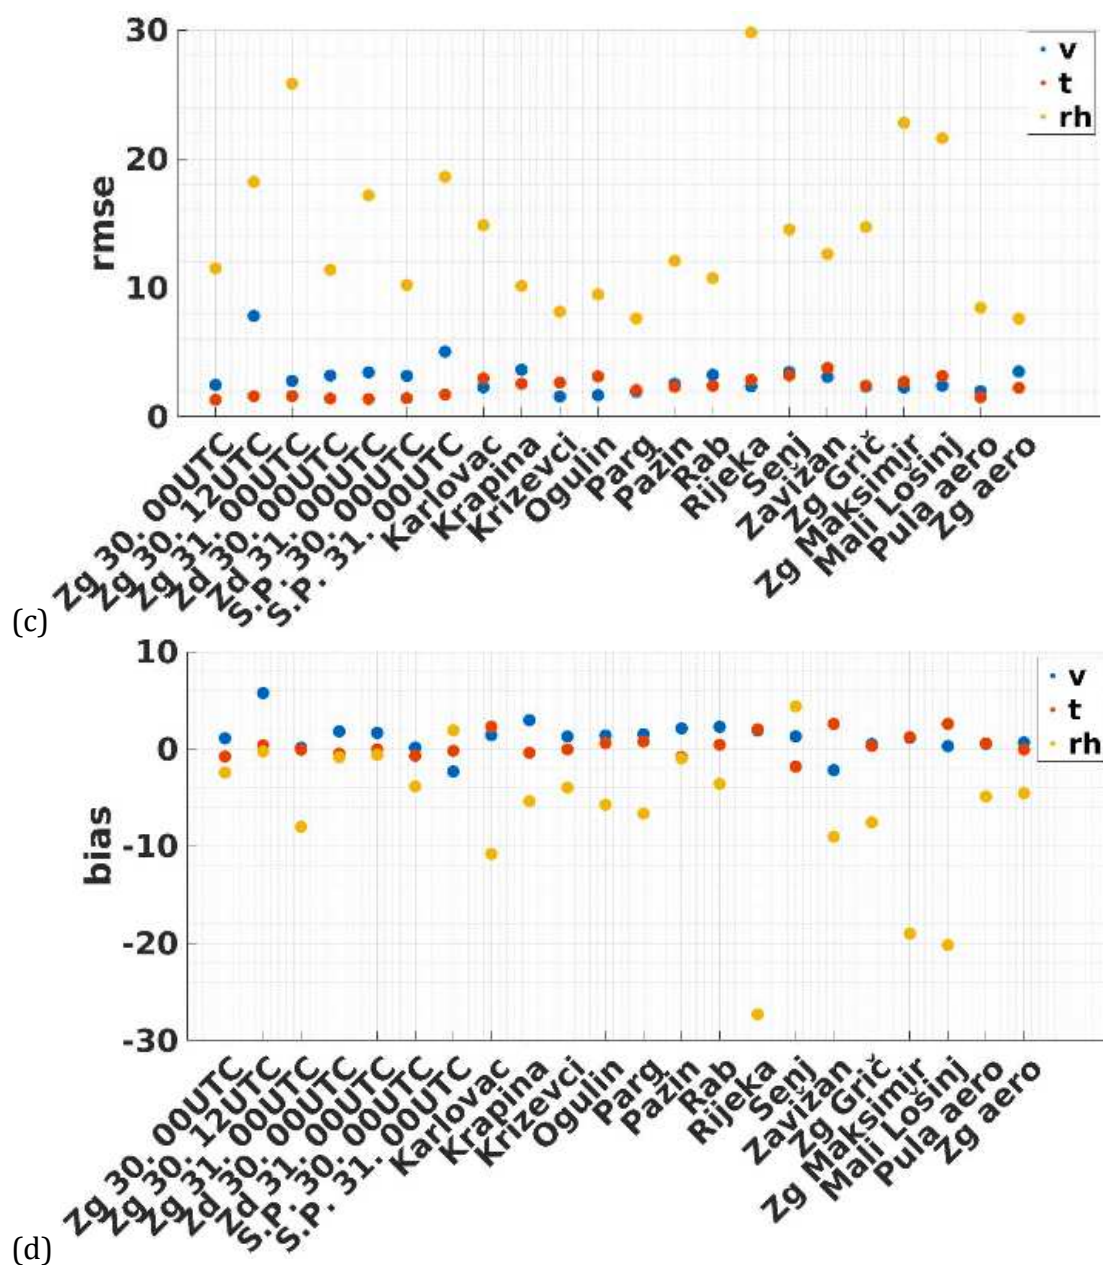
Za radiosondažne podatke T , korelacija je vrlo visoka ako se računa na vertikalnim profilima. Vrlo visoka korelacija za sve parametre, a osobito za T posljedica je velikog broja nivoa i bolje reprodukcije modeliranih uvjeta atmosfere u višim slojevima. Određena neslaganja u prizemnom sloju ili na slojevima diskontinuiteta u atmosferi (Slika 14) nisu imala velik utjecaj na iznos r . Pristranost modela je vrlo mala gledajući usporedbu po visini.

Prizemne postaje pokazuju nižu korelaciju u vremenu za T , te je za većinu postaja r veći od 0.5. Izuzetak su postaje Ogulin, Senj, Mali Lošinj, gdje postoji veliki rasap rezultata modela oko mjerenih podataka. Iako su pogreške modela za T (MAE , $RMSE$) manje za vertikalne profile u usporedbi s onima za vremenske nizove po postajama, one ne prelaze 4 °C, što je u skladu s drugim studijama evaluacije modela WRF (npr., Kehler-

Poljak et al., 2017.). Ipak usporedba u vremenu prizemnih nizova pokazuje da postoji jednak broj postaja s precjenjivanjem i podcjenjivanjem T unutar intervala pristranosti od -2°C do 2°C .



Slika 15: Statistički parametri za razdoblje 30.-31.07.2014.: (a) koeficijent korelacije (r), (b) srednja apsolutna pogreška (MAE), (c) korijen srednje kvadratne pogreške ($RMSE$) i (d) pristranost ($bias$) za brzinu vjetra (v , m/s; plavo), temperaturu (T , $^{\circ}\text{C}$; crveno) i relativnu vlažnost (rh , %; žuto). Statistička evaluacija provedena je na podacima triju radiosondažnih postaja Zagreb-Maksimir, Zadar, i San Pietro Capofiume (prvih 7 vrijednosti na x-osi), na prizemnim podacima 13 standardnih postaja u okviru mreže Državnog hidrometeorološkog zavoda te dviju zračnih luka Pula i Zagreb.



Slika 15: nastavak.

Razlog za niže/lošije vrijednosti kod usporedbe vremenskih nizova je moguće pronaći u simulaciji ekstremnih vrijednosti u temperaturnom dnevnom hodu. Tmax i Tmin su često simulirani lošije zbog parametrizacija turbulencije i zračenja. Dok se Tmin obično precjenjuje, Tmax se podcjenjuje. Najveći problemi s pravilno simuliranim dnevnim temperaturnim ciklusom se javljaju na obalnim postajama u kompleksnom terenu (npr., Kehler-Poljak *et al.*, 2017.; Belušić *et al.*, 2018.). Na tim postajama temperaturni hodovi ovise o međusobnoj interakciji kopno-more, pravilno definiranoj topografiji odnosno zemljišnom pokrovu okruženja postaje, kao i o lokalnoj cirkulaciji atmosfere.

Koeficijenti korelacije za brzinu vjetra ukazuju na nešto slabiju, ali još uvijek visoku korelaciju kod više od polovice postaja korištenih u analizi. Uvažavajući pogreške

i pristranost, lošije su simulirana dva radiosondažna termina; može se vidjeti precjenjivanje brzine vjetra na postaji Zagreb-Maksimir u 12:00 UTC 30.07.2014. i podcjenjivanje u San Pietro Capofiume u 00:00 UTC 31.07.2014. Od standardnih postaja ističu se lošiji rezultati za (najvišu hrvatsku) planinsku postaju Zavižan na kojoj je vidljivo osim precjenjivanja temperature, podcjenjivanje strujanje, ali i vlažnosti, moguće zbog izgladene visine topografije u modelu, odnosno niže visine postaje u modelu.

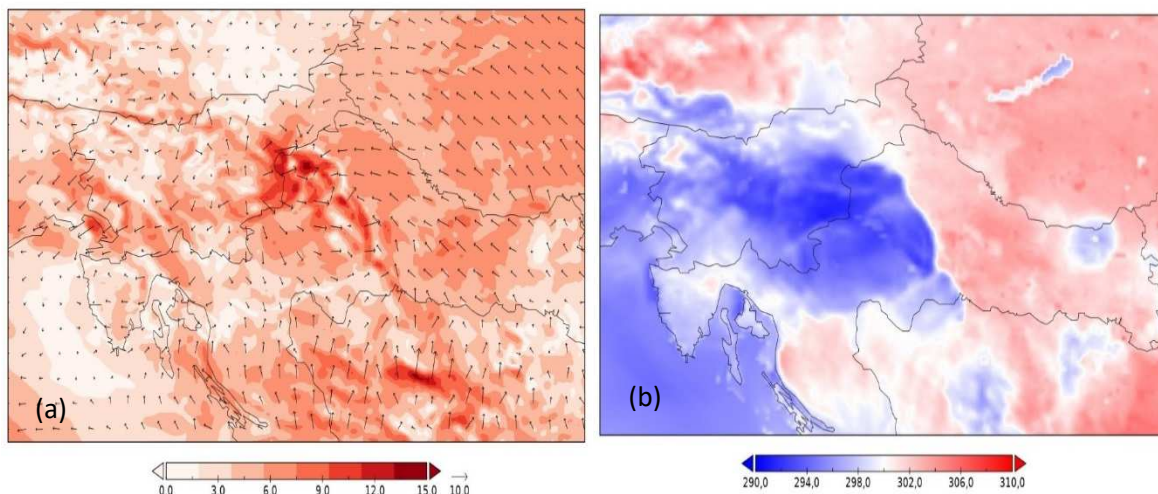
Među analiziranim parametrima, koeficijenti korelacije su najmanji za rh ; najčešće su pozitivni i umjereni, ali ima postaja na kojima je korelacija pozitivna i slaba ili negativna i vrlo slaba pa čak i nepostojeća. Većina odstupanja rh su unutar 7 do 20 % bez obzira radi li se o MAE ili $RMSE$. Gledajući pristranost, model uglavnom podcjenjuje vlažnost s izuzetkom dviju promatranih postaja što je čest slučaj kod korištenja nelokalnih shema za granični sloj (YSU) u modelu WRF (npr., Kehler-Poljak *et al.*, 2017.). Za postaju Rijeka postoje najveće pogreške i pristranost za rh . Za sada nije jasan uzrok ovog ekstremnog rezultata za tu postaju.

Uzroci podcjenjivanja rh iznosa najvjerojatnije su višestruki. Iako neka od ograničenja modela svakako pridonose razlikama (razlučivost modela vezana uz mrežni korak, niz parametrizacija, (ne)točnost ulaznih i rubnih podataka, prikaz topografije itd.), dio izvora odstupanja moguć je zbog reprezentativnosti samih mjerenja. Iz izvješća METAR, rh podaci izračunati su na temelju zaokruženih T na cijeli stupanj. To znači da će se u proračunu za rh koristiti ista T od npr. 20°C za cijeli interval vrijednosti izmjerenih T od 19.5 °C do 20.4 °C, što će dati isti podatak za rh . Navedena odstupanja od stvarnih rh vrijednosti mogu biti 5-10%, ovisno o vrijednostima T . Također treba naglasiti da rh varijabla nije izlazna varijabla modela WRF, već se i ona proračunava te time neizbježne pogreške u simuliranim temperaturama, tlaku, i omjeru miješanja opterećuju proračun.

Uvažavajući sve statističke rezultate kao i ograničenja modela, na kraju se može zaključiti da je podudaranje između mjerenja i modela zadovoljavajuće što nam omogućava daljnju analizu meteoroloških parametara.

3.2.2 Analiza modeliranih meteoroloških polja za slučaj 30.-31. srpnja 2014.

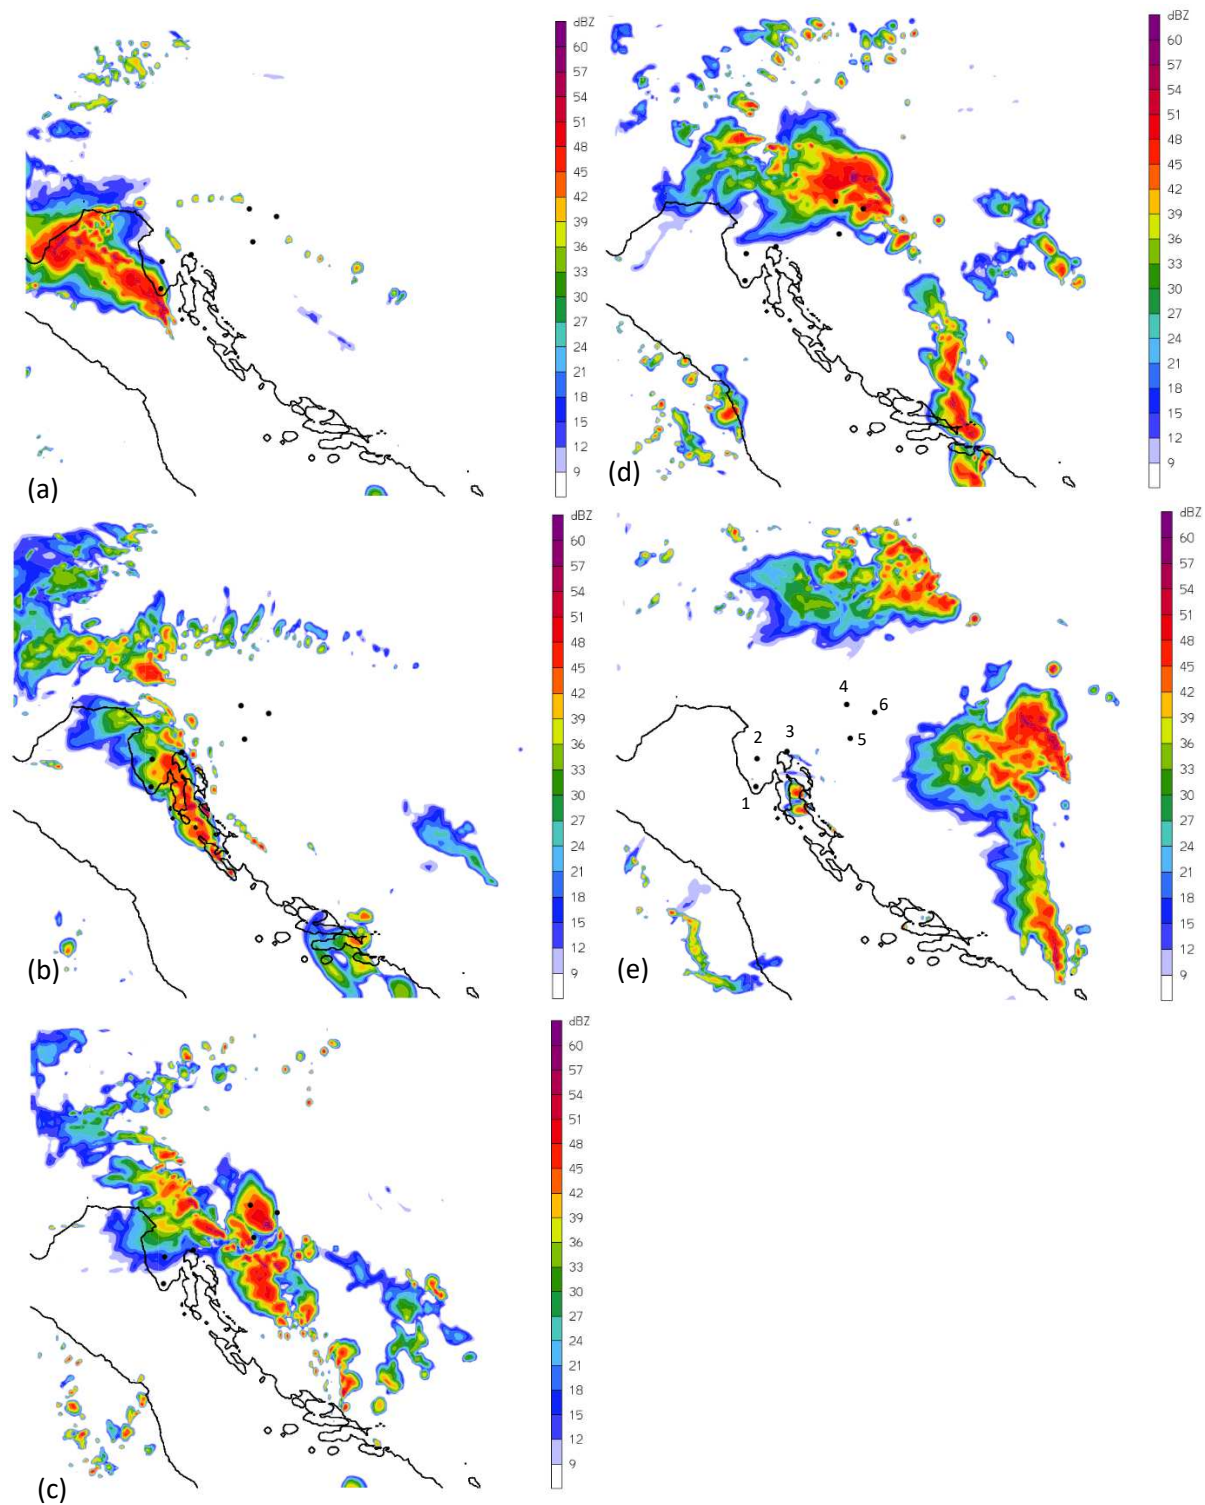
Iako je ciklona zahvatila veći dio Hrvatske, ovdje je fokus na područje koje je pokriveno mjerenjima tuče; odnosno sjeverozapadni i središnji dio Hrvatske. U skladu s radarskim slikama s lokacije Lisca (Slika 13), modelirana konvektivna struktura se razvija nad područjem interesa oko 14:00 UTC (Slika 16). Pojava konvektivne aktivnosti vidljiva je u prizemnom vrtložnom strujanju kao zona povećanih brzina vjetra, predstavljajući fronte udara vjetra ispod konvektivnih ćelija. Ovo područje se proteže od granice sa Slovenijom do granice s BiH (Slika 16a, tamno crvene boje). Nadalje, polje temperature (Slika 16b) ukazuje na bazen hladnog zraka (s $\Delta T \sim 6$ °C, a povezujemo ga s propagacijom oluje. Uočimo da je upravo prethodno navedene zone povećanih brzina predstavljaju granicu toplog i hladnog zraka.




Slika 16: Modelirane vrijednosti (a) prizemnog vjetra (m/s) na 10 m AGL i (b) prizemne (2-m) potencijalne temperature (K) za 30.07.2014. u 14:00 UTC

Modelirane vrijednosti maksimalnog radarskog odraza u ranim jutarnjim satima (05:00 UTC, Slika 17a) ukazuju na jaču konvektivnu aktivnost nad sjevernim Jadranom i jugozapadnim dijelom Istre. Uspoređujući ih s izmjerenim vrijednostima (04:00 UTC, Slika 13a), model je prognozirao nešto kasnije više konvektive aktivnosti iznad morske površine. I tijekom sljedećih sati model zadovoljavajuće rekonstruira gibanje sustava konvektivnih ćelija u prostoru. Ipak u modelu, konvektivna aktivnost je jačeg intenziteta te se uočava njeno sporije pomicanje prema istoku u odnosu na ono u mjerenjima (Slike 13b i 17b). Oko podneva, Slika 17c, model dobro simulira razvoj konvektivnih ćelija u prostoru (izraženi maksimum u području između Karlovca i Zagreba), ali ponešto precjenjuje intenzitet i prostornu pokrivenost konvekcije na ostalom području. Usporedba modeliranog maksimalnog radarskog odraza u 14:00 UTC (Slika 17d) s izmjerenim u 13:50 UTC (Slika 13d) pokazuje dosta dobro slaganje u pojavi konvektivnih ćelija gledajući prostorno-vremensku raspodjelu te intenzitet radarskog odziva (> 48 dBZ). Kako je korištenje radarskih produkata u prognozi tuče na široko prihvaćeno, smatra se da su radarski odrazi > 50 dBZ vrlo dobar indikator/potvrda pojavi tuče. U večernjim satima, nad područjem središnje i sjeverozapadne Hrvatske, vrijednosti maksimalnog radarskog odziva su jednake nuli (Slika 17e), što je u skladu s mjerenim vrijednostima (Slika 13f), s iznimkom u području Varaždina.

Kako se tijekom poslijepodnevni sati konvektivne ćelije advektiraju prema sjeveroistoku, a konvektivna aktivnost nad područjem interesa slabi, nad promatranim područjem prizemni vjetar je slab ili ga gotovo nema (Slika 18a). Prolazak konvektivnog sustava bio je povezan s prodorom hladnog zraka (slika 18b) uzrokujući stabilizaciju vremena, što je u skladu s opisanom sinoptičkom situacijom.



Slika 17: Modelirane vrijednosti maksimalnog radarskog odraza (dBZ) za 30.07.2014. u (a) 05:00 UTC, (b) 09:00 UTC, (c) 12:00 UTC, (d) 14:00 UTC, (e) 18:00 UTC. Crne točke označavaju postaje na kartama (s lijeva na desno): zračna luka Pula (1), Pazin (2), Rijeka (3), Krško (4), Karlovac (5) i Zagreb (6)

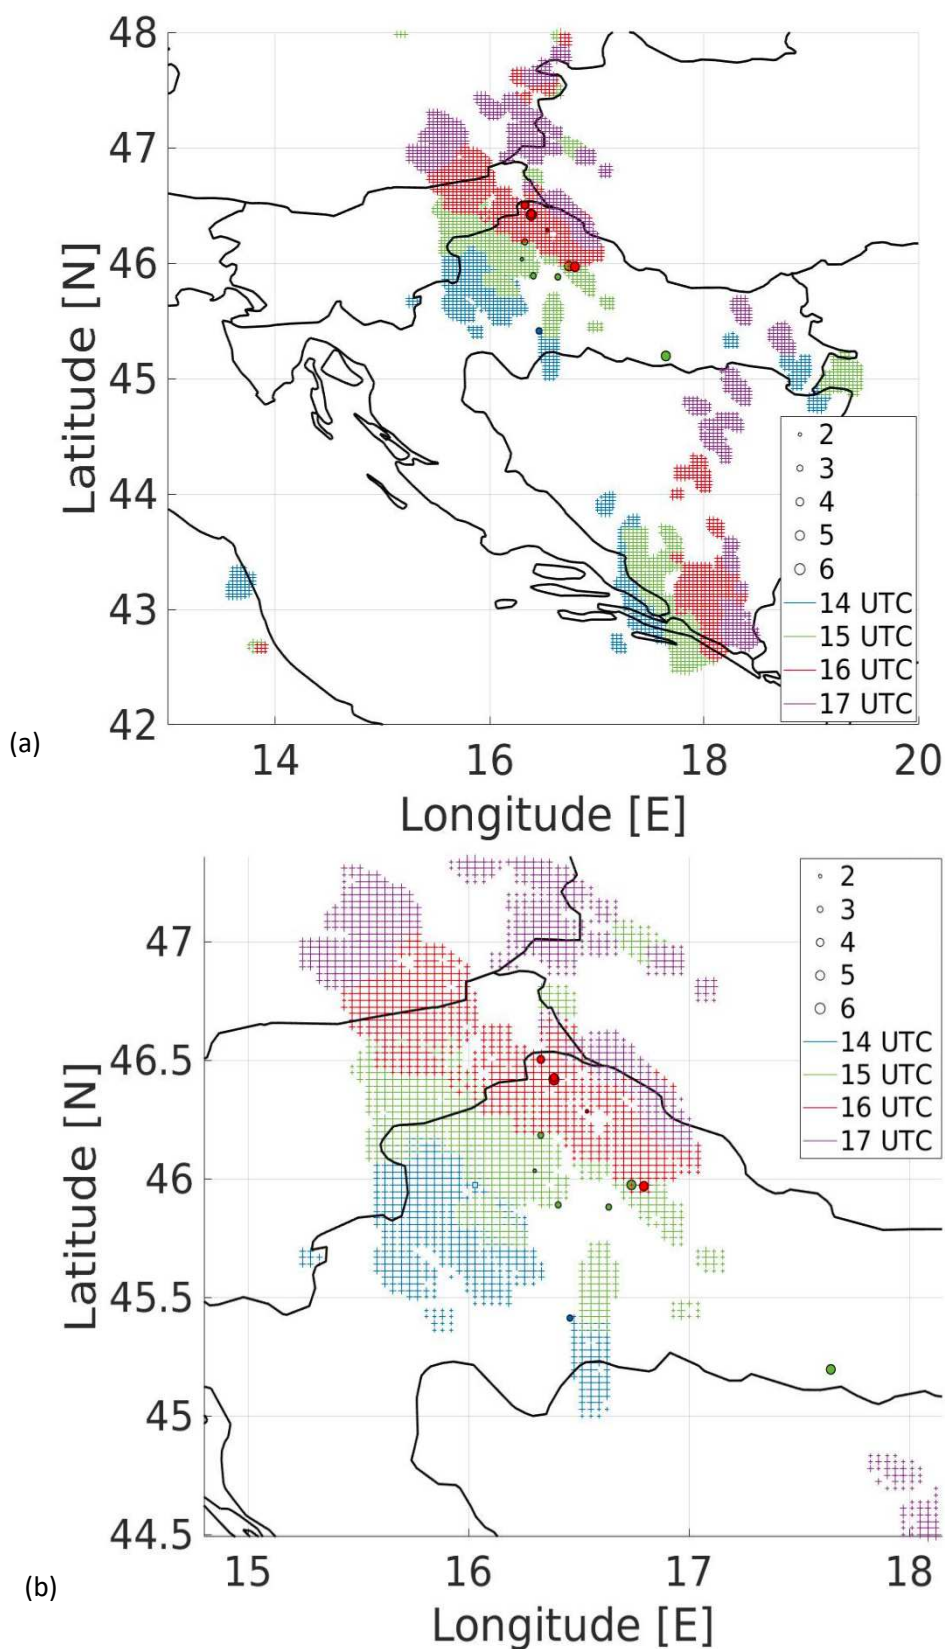


Slika 18: Modelirane vrijednosti (a) prizemnog vjetrova (m/s) na 10 m AGL, (b) prizemne (2-m) potencijalne temperature (K) za 30.07.2014 u 23:00 UTC

S obzirom da je model relativno dobro reproducirao intenzitet, prostornu pokrivenost i vremenski tijek konvektivne aktivnosti, moguće je s većom sigurnošću analizirati zabilježen događaj tuče. Na Slici 19 prikazani su modelirani i izmjereni maksimalni promjeri tuče. Boje predstavljaju vrijeme, a veličina kružića i križića izmjerene, odnosno modelirane maksimalne promjere tuče klasificiranih prema kategoriji tuče. Valja napomenuti da je zapis rezultata modela 1 h, dok su mjerenja trenutna pa postoji „problem” pridjeljivanja pojave tuče određenom intervalu. U ovome radu je sva zabilježena tuča unutar punog sata pridijeljena ranijem vremenu (npr. tuča izmjerena u razdoblju 14:00 – 15:00 UTC je pridijeljena vremenu od 14:00 UTC).

Analizirano područje (Slika 19b) prekriveno je mnogobrojnim tučomjerima te je 12 njih uspjelo zabilježiti tuču. Tablica 2 pokazuje dodatne parametre mjerene tuče po postajama. Ona sadrži podatke o: KE, toku energije, ukupnoj masi i broju zrna tuče po m^2 , razredu zrna tuče u kojem je navise palo krute oborine, razredu maksimalnog promjera tuče, kao i izmjenom maksimalnom promjeru zrna. U posljednjem stupcu nalaze se modelirane vrijednosti maksimalnog promjera tuče u skladu sa Slikom 19.

U razdoblju od 14:00 – 15:00 UTC je zabilježena tuča na jednoj postaji u blizini Siska (plavi kružić na Slici 19b) u trajanju od 10 minuta. Ukupan broj zrna/ m^2 je 240, masa 56,67 g/ m^2 , KE 2,67 J/ m^2 i tok energije 4,44 mW/ m^2 . Najveći broj zabilježenih zrna pripada prvoj klasi (5-7,5 mm), dok maksimalni izmjereni promjer pripada 3. klasi (10-12,5 mm). U razdoblju od 15:00 – 16:00 UTC šest je postaja od Zagreba prema Ivanić Gradu zabilježilo tuču (zeleni kružići). Maksimalni zabilježeni promjer pripada 2. kategoriji (7,5 -10 mm), ukupan broj zrna/ m^2 jednak je 80, masa 72,45 g/ m^2 , KE 5,28 J/ m^2 i tok energije 29,36 mW/ m^2 , a samo padanje je trajalo 5 minuta. Sljedeće tri postaje zabilježile su maksimalne promjere tuče koje pripadaju 3. kategoriji (10-12,5 mm) u trajanju od 2, 10 odnosno 3 minute. KE su redom 1,27 J/ m^2 , 7,4 J/ m^2 , 1,8 J/ m^2 , a ukupan broj zrnaca 128, 1280 i 96. Kod zabilježenih maksimalnih promjera koji pripadaju 5. kategoriji (15-17.5 mm) KE redom su jednake 5,3 J/ m^2 i 148,15 J/ m^2 , a zabilježene su u blizini Požege. Navedena lokacija odgovara području s najvećom zabilježenom masom i najvećim ukupnim brojem zrna/ m^2 u prvoj epizodi; 2133,4 g/ m^2 , 3808. U razdoblju 16 – 17 UTC, pet postaja je zabilježilo tuču, a posebno je zanimljiva postaja u blizini Čakovca sa zabilježenom tučom 6. kategorije (17.5-20 mm). Proces padanja je trajao 13 minuta, zabilježen je ukupan broj od 832 zrna/ m^2 , KE jednaka je 48,38 J/ m^2 , a masa 560,78 g/ m^2 .



Slika 19: Modelirani (križići) i izmjereni (kružići) maksimalni promjeri tuče na (a) čitavoj domeni (b) analiziranom području prekriveno mrežom tučomjera u razdoblju 14 :00– 17:00 UTC 30.07.2014. Kružići odgovaraju razredima tuče od 2 do 6, a boje odgovaraju satima. Razredi rastu za svakih 2.5 mm počevši od 5 mm; 2. razred opisuje promjere zrna u intervalu vrijednosti 7.5-10 mm; 3. razred 10-12.5 mm, 4. razred 12.5-15 mm, 5. razred 15-17.5 mm i 6. razred 17.5-20 mm. Najveći promjer zabilježen je u blizini Čakovca s tučom 6. kategorije.

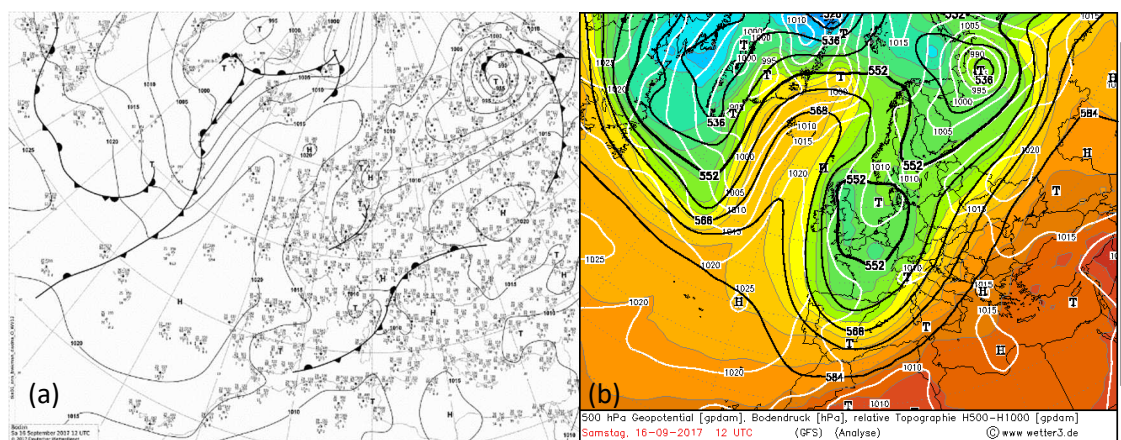
Tablica 2: Podaci o zabilježenoj tuči u razdoblju 14 – 17 UTC 30.07.2014 i usporedba s (najbližim) modeliranim maksimalnim promjerom tuče (mm). U tablici maksimalni mjereni promjer zrna je označen s d (mm) i iz modela s d_{WRF} (mm).

Vrijeme	Šifra tučomjera	Geog. širina (°)	Geog. dužina (°)	Blizina većeg mjesta	Najveći broj zrna promjer (mm) /razred zrna	KE (J/m ²)	Vrijeme trajanja (min)	Ukupan broj zrna/m ²	Ukupna masa zrna (g/m ²)	Tok energije (W/m ²)	d (mm) /razred zrna	d_{WRF} (mm) /razred zrna
14-15 UTC	4118	16.4598	45.4122	Sisak	5-7.5 (1.)	2.67	10	240	56.67	4.44	10.1-12.5 (3.)	9.8 (2.)
15 – 16 UTC	2081	16.3273	46.1838	Novi Marof	5-7.5 (1.)	1.27	2	128	27.6	10.59	10.1-12.5 (3.)	13.71 (4.)
	2086	16.2999	46.0335	Sveti Ivan Zeline	7.6-10 (2.)	0.82	5	80	19.26	2.74	7.6-10 (2.)	13.97 (4.)
	9080	16.7385	45.9740	Bjelovar	5-7.5 (1.) 7.6-10 (2.)	5.28	3	160	72.45	29.36	15.1-17.5 (5.)	12.14 (3.)
	9077	16.6357	45.8804	Bjelovar	5-7.5 (1.)	1.8	3	96	33.31	10	10.1-12.5 (3.)	10.27 (3.)
	9069	16.4063	45.8896	Vrbovec	5-7.5 (1.)	7.4	10	1280	197.28	12.34	10.1-12.5 (3.)	9.31 (2.)
	9072	17.6433	45.1956	Požega	7.6-10 (2.)	148.15	5	3808	2133.46	493.83	15.1-17.5 (5.)	-
16 – 17 UTC	2005	16.3880	46.4271	Čakovec	5-7.5 (1.)	5.85	2	384	111.40	48.79	12.6-15 (4.)	24.26 (8.)
	2002	16.3276	46.5030	Sveti Martin na Muri	5-7.5 (1.)	4.27	2	320	81.38	35.56	12.6-15 (4.)	10.15 (3.)
	2010	16.3873	46.4187	Čakovec	5-7.5 (1.)	48.38	13	832	560.78	62.02	17.6-20 (6.)	24.26 (8.)
	2071	16.5372	46.2841	Ludbreg	5-7.5 (1.)	2.31	5	400	63.04	7.69	7.6-10 (2.)	10.28 (3.)
	9083	16.7953	45.9685	Bjelovar	15.1-17.5 (5.)	20.5	1	176	225.1	341.69	15.1-17.5 (5.)	10.43 (3.)

Model je dosta dobro simulirao događaje (vremenski i prostorno), ali je zahvatio preveliko područje. Nadalje, jasno je vidljiv smjer premještanja oluje s tučom od jugozapada prema sjeveroistoku, što je u slaganju s prethodno opisanim pomicanjem ciklonalnog sustava.

3.3 Karakteristike slučaja 16.-17. rujna 2017.

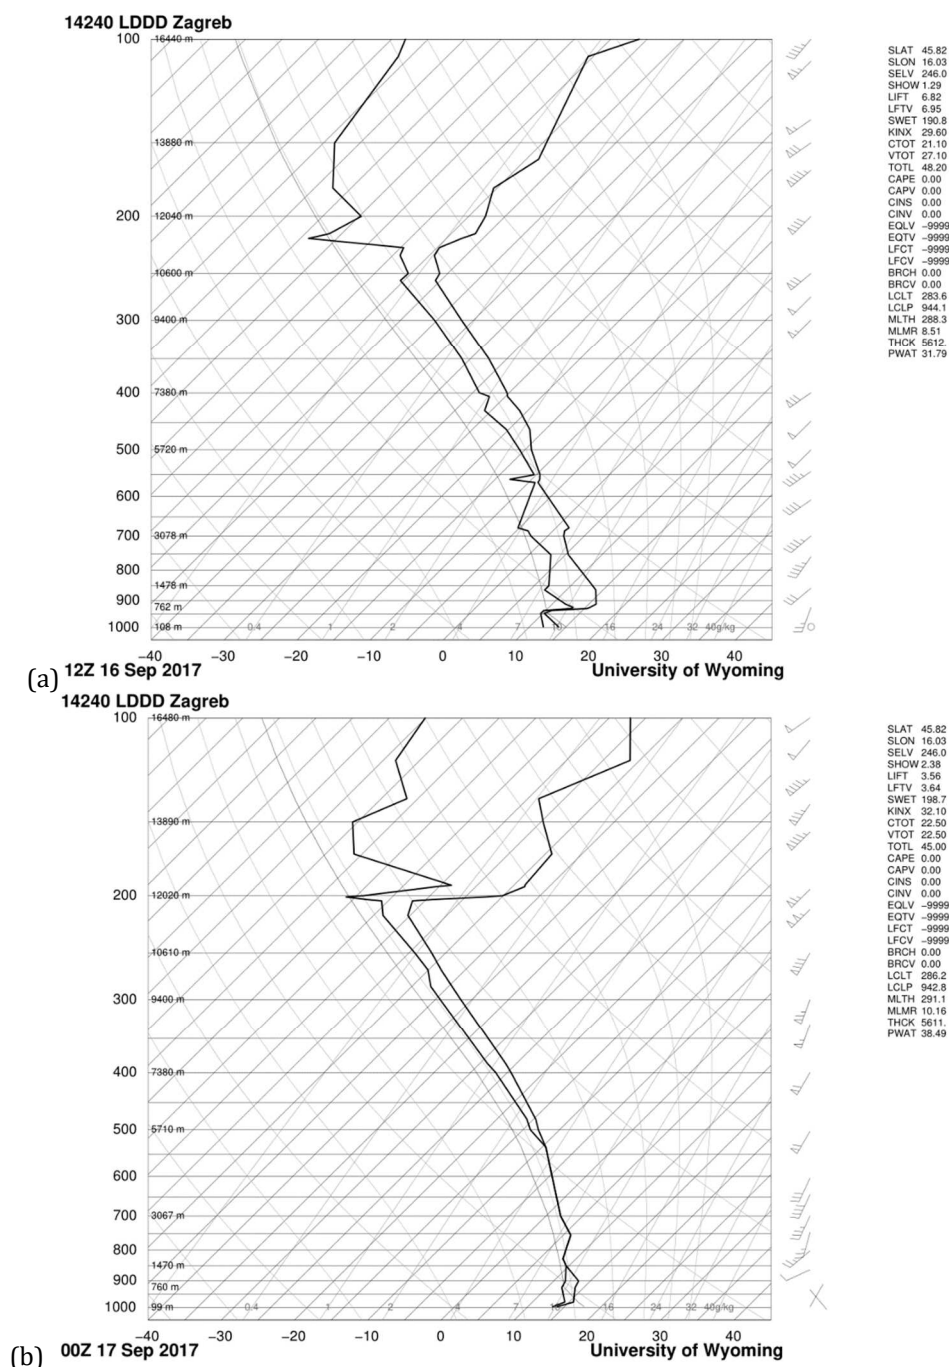
Druga odabrana epizoda obuhvaća razdoblje od 00:00 UTC 16. rujna do 06:00 UTC 17. rujna 2017. godine. Fokus je na istom području interesa gdje se dogodila pojava tuče u večernjim satima. U promatranom razdoblju, sinoptički uvjeti ukazuju da se područje Hrvatske nalazi pod utjecajem prednje strane prostrane, duboke i intenzivne doline u polju tlaka (Slika 20). Sama dolina se spušta od Skandinavskog prema Pirinejskom poluotoku. Istodobno, nad samom Hrvatskom prizemno nema jakih gradijenata u polju tlaka, ali se nailaskom doline nad Alpe stvara manja plića ciklona nad Genovskim zaljevom. Ciklona započinje premještanje u smjeru istoka prvo preko Apeninskog poluotoka te potom duž osi Jadrana. Po visini dominiraju jaki gradijenti u polju tlaka nad Hrvatskom tijekom čitavog razdoblja. Stoga se u sredini troposfere javlja jugozapadna mlazna struja (brzina oko 30 m/s) na prednjoj strani visinske ciklone povlačeći s juga po visini vlažan i topao zrak.



Slika 20: (a) Prizemna dijagnostička karta Europe i (b) visinska sinoptička karta 16.09.2017. u 12:00 UTC (izvor: <http://www1.wetter3.de/>)

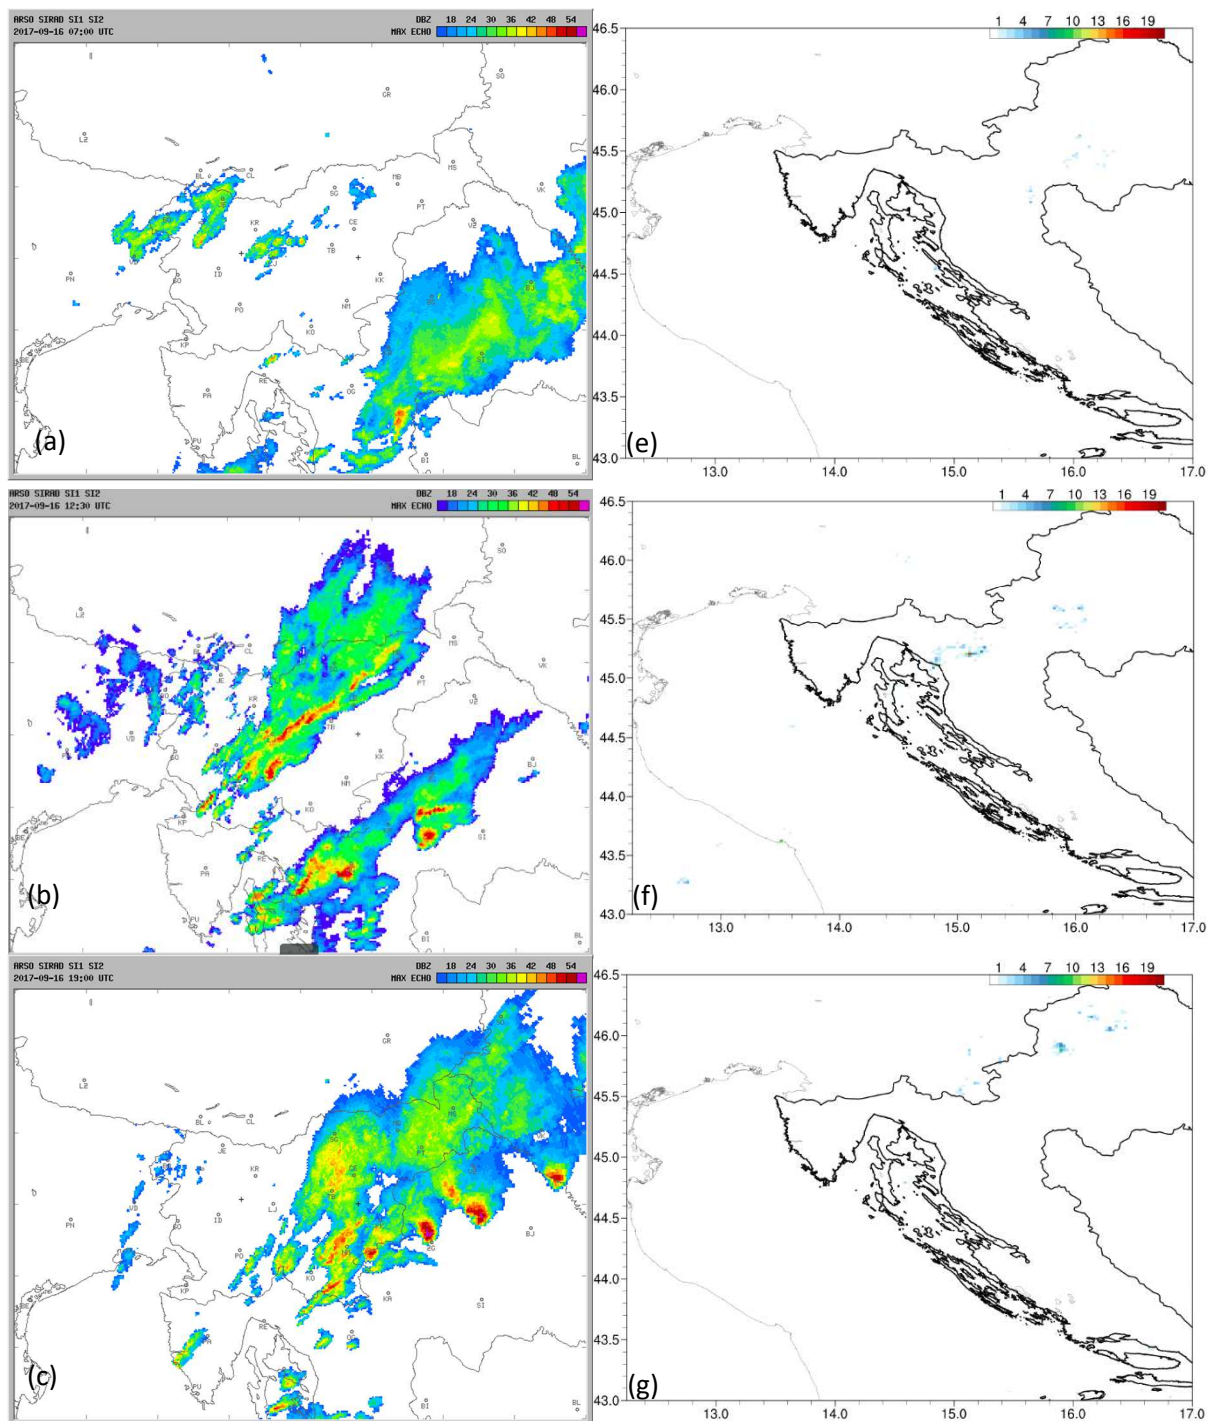
Za podne 16.09.2017. je prikazan vertikalni profil atmosfere nad Zagrebom na Slici 21. Dnevne vrijednosti *K*-indeksa ($KI=29,60$) i *Total Totals* indeksa ($TOTL=48,2$) ukazuju na mogućnost pojave olujnog nevremena tog dana (Slika 21a), iako isto nije vidljivo u konvektivnoj raspoloživoj potencijalnoj energiji ($CAPE=0 \text{ Jkg}^{-1}$) i pozitivnom indeksu podizanja ($LI=6,82$). Razina smrzavanja se otprilike nalazi na izobarnoj plohi 660 hPa. Prevladavajući jugozapadni vjetar slabo mijenja smjer po visini dosežući 25 m/s na 500 hPa plohi uz značajno smicanje strujanja u prvih 6 km iznad tla. Noćne vrijednosti konvektivnih indeksa ne razlikuju se mnogo od dnevnih (Slika 21b). Vrijednosti *K*-indeksa su i dalje velike ($KI=32,10$), konvektivne raspoložive potencijalne energije je ostala ista ($CAPE=0 \text{ Jkg}^{-1}$), a indeks podizanja je i dalje pozitivan ($LI=3,56$). Razina

smrzavanja se otprilike nalazi na 680 hPa izobarnoj plohi, i dalje postoji mala razlika u deficitu rosišta ($T-T_d$) koja se proteže gotovo čitavom troposferom ukazujući na velik dotok vlage.

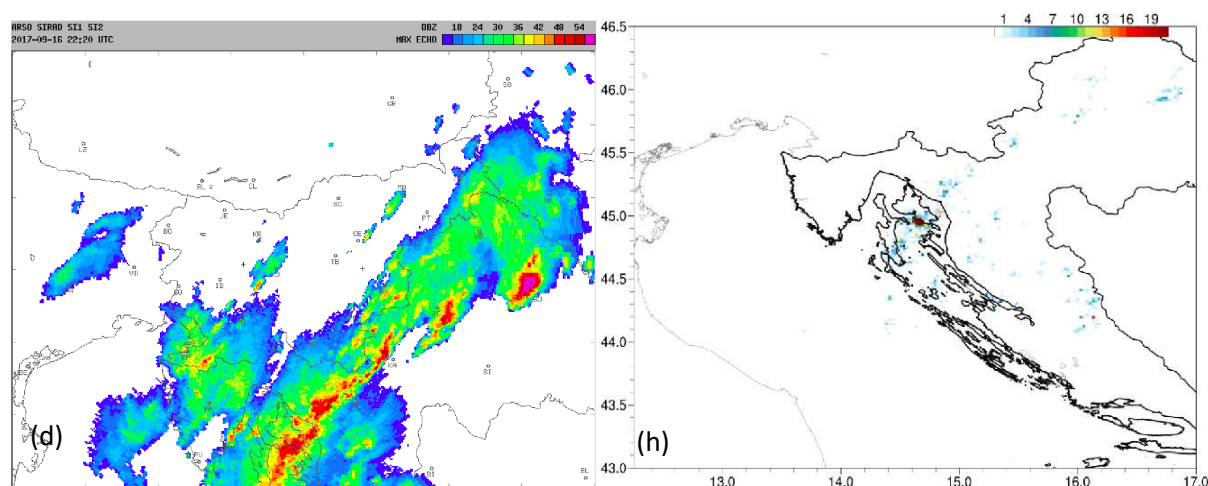


Slika 21: Termodinamički dijagram radiosondaže za postaju Zagreb – Maksimir (a) 16.09.2017. u 12 UTC i (b) 17.09.2017. u 00 UTC (izvor: <http://weather.uwyo.edu/upperair/sounding.html>)

U jutarnjim satima maksimalni mjereni radarski odraz (Slika 22a) ukazuje na lokalnu konvektivnu aktivnost na području sjeverno od Rijeke i gorskoj Hrvatskoj na granici s BiH. Potencijalno područje za razvoj konvekcije (> 40 dBZ) prostire se duž većeg dijela središnje Hrvatske u kojem je lokalno zabilježen manji broj udara munja (Slika 22d). U rano poslijepodne, formirane su dvije veće oblačne strukture jedna sjevernija nad Slovenijom i druga južnija nad kvarnerskim otočjem (Slika 22b) koja seže sve do Zagreba.



Slika 22: (a, b, c, d) Maksimalan radarski odraz (dBZ) (izvor: <http://www.arso.gov.si>) i (e, f, h, g) broj udara munje (podaci iz LINET baze) za 16.09.2017. u (a, e) 07:00 UTC, (b, f) 12:30 UTC, (c, g) 19:00 UTC, (d, h) 22:20 UTC



Slika 22: Nastavak

Unutar južne strukture jak maksimalan radarski odraz (> 50 dBZ) definira postojanje više konvektivnih ćelija nad Likom i u području između Karlovca i Siska, što potvrđuje i zapis udara munja (Slika 22e). U vremenu dvije oblačne strukture se sjedinjuju te je u večernjim satima jasno vidljiv linijski raspored ćelija Cb-a od granice sa Slovenijom do granice s Mađarskom (Slika 23c). Najveće vrijednosti maksimalnog radarskog odraza (> 54 dBZ) i veći broj udara munja (Slika 23f) izmjerene su na području Zagreba i zapadno od Križevaca. Stoga, nad tim područjem potencijalno očekujemo pojavu tuče. U noći, sustav i dalje jača; vrijednosti maksimalnog radarskog odraza > 48 dBZ protežu se od mora preko gorske Hrvatske do Mađarske (Slika 23g). Nad područjem interesa konvektivnu aktivnost očekujemo u području zapadno od Karlovca i istočno od Zagreba. U području Bjelovara izmjeren je najjači radarski odraz (> 54 dBZ), što ukazuje na potencijalno jaču oluju s tučom. Nadalje, Slika 23h prikazuje broj udara munja u 22:20 UTC. Područja s visokim iznosima maksimalnog radarskog odraza su povezana s brojem udara munja (Slika 23 h). Iznimno velik broj udara munja je zabilježen u području kvarnerskog otočja.

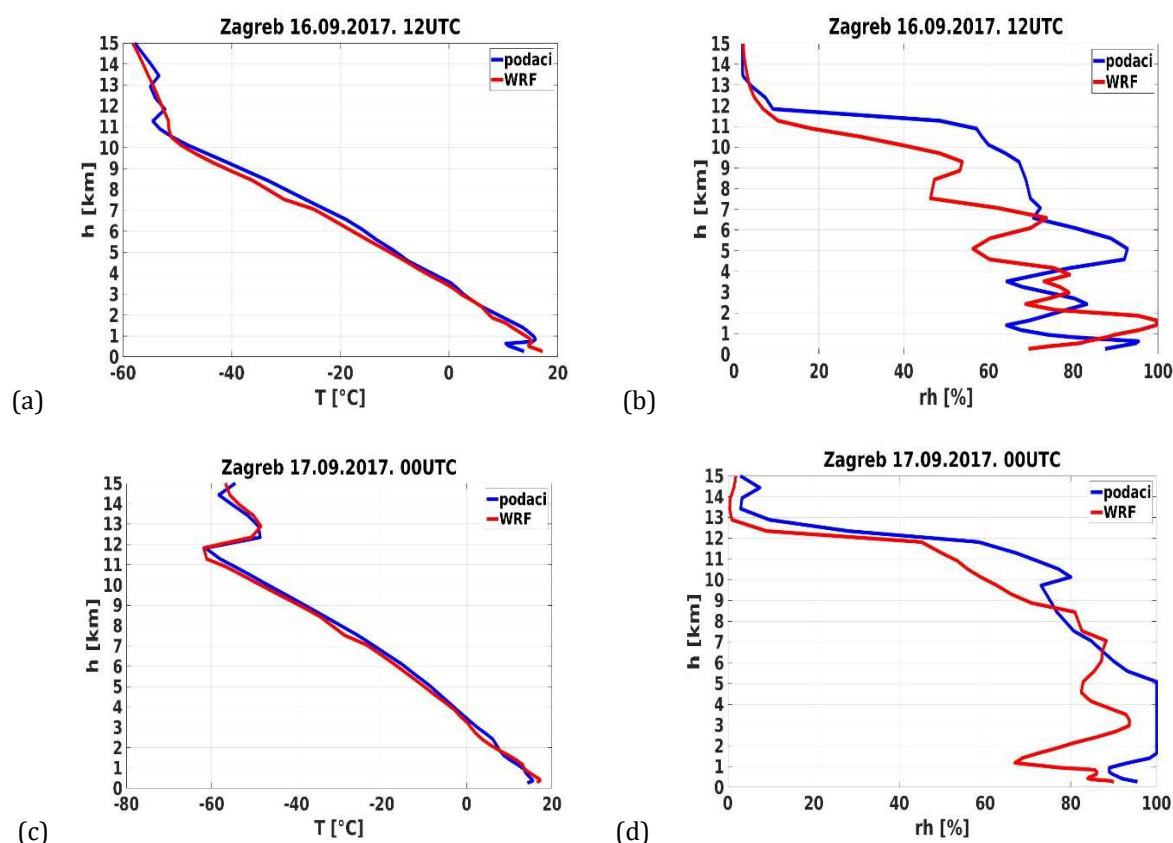
Propagacija ćelija Cb-a je u skladu s jugozapadnim strujanjem. Prema radarskim slikama konvektivna aktivnost nad promatranim područjem započinje u 00:50 UTC u blizini Karlovca (do 48 dBZ), a lokalno je prisutna gotovo kroz čitavo promatrano razdoblje. U rano poslijepodne zabilježene su prve značajnije vrijednosti maksimalnog radarskog odziva (> 50 dBZ; Slika 23b). U području sjeverozapadne Hrvatske, od 15:40 UTC do 22:50 UTC, lokalno se javljaju ćelije Cb-a s maksimalnim radarskim odzivom > 54 dBZ. Iza ponoći nema značajnih vrijednosti radarskog odziva. Veći broj udara munja nad Hrvatskom započinje u 12:25 UTC. Očekivano, veći broj udara munja prati veće vrijednosti radarskog odziva. Stoga, zabilježeni maksimalni broj udara se vremenski poklapa s najvećim vrijednostima maksimalnog radarskog odziva

3.4 Analiza rezultata WRF modela za slučaj 16-17. rujna 2017.

U podnevnom terminu 16.09.2017., model (crveno na Slici 23) pokazuje dobro slaganje s izmjerenim vrijednostima (plavo) i za T i rh (Slike 23a, b). Modelirani granični sloj je topliji od mjenog, precjenjujući T , dok je preostali dio atmosfere dobro

reproduciran. Ukoliko se promatra vlažnost atmosfere prevladava podcjenjivanje mjerenih vrijednosti.

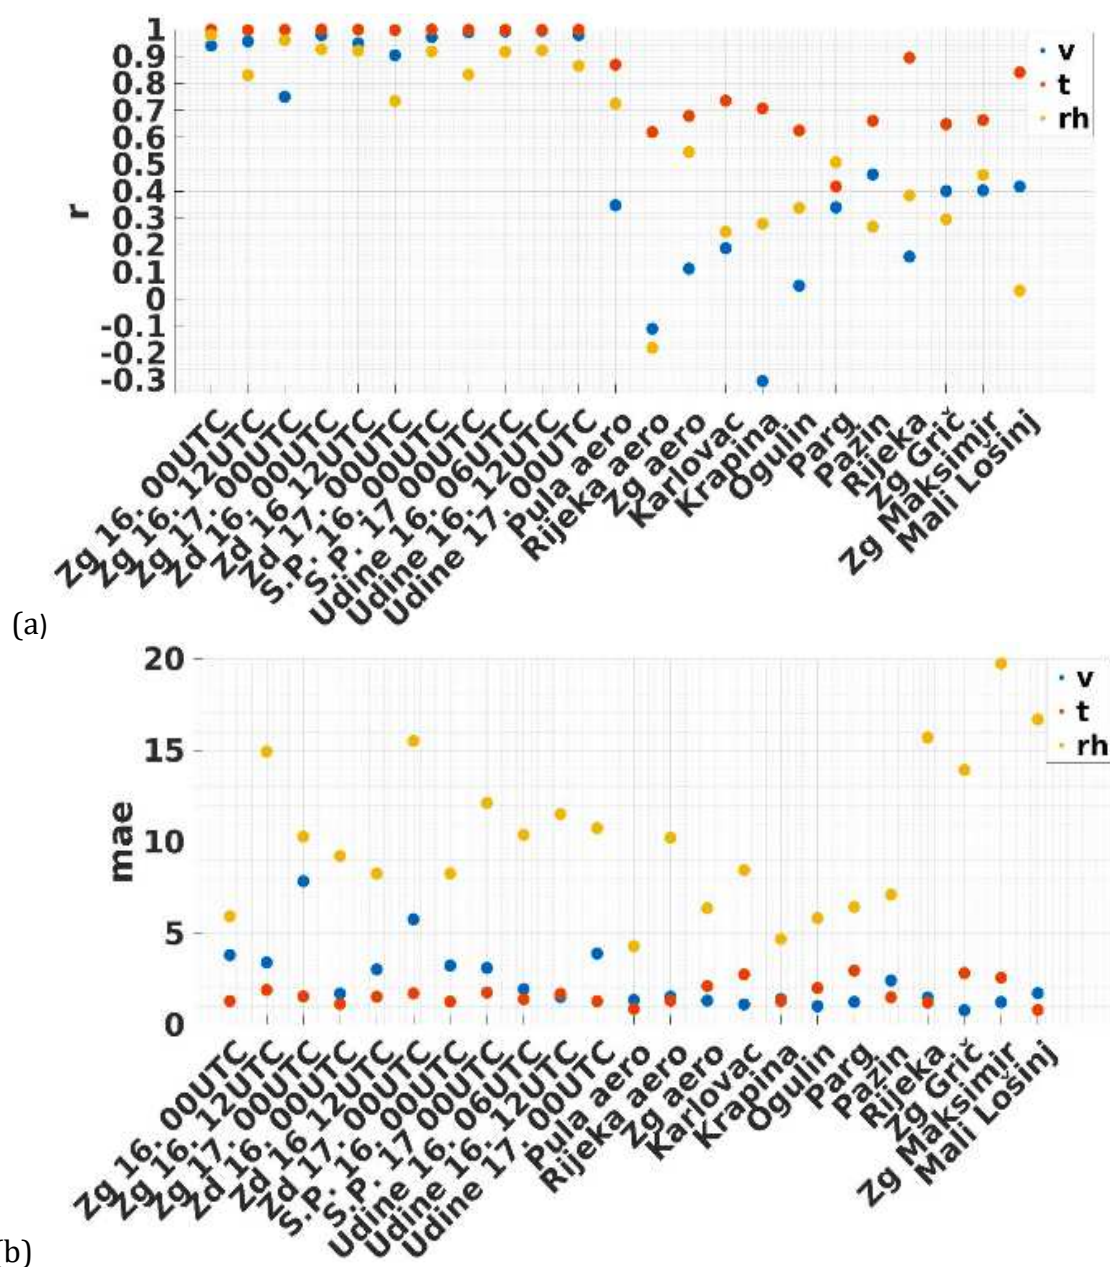
Ponoćni vertikalni profili T i rh postaje Zagreb – Maksimir (u 00:00 UTC), prikazani su na Slikama 23c i 23d. Model je uspješno reproducirao vertikalni profil T s manjim odstupanjima u noćnom graničnom sloju od dnevnog. Iako model podcjenjuje vrijednosti rh od tla sve do 6.5 km, poklapanje izmjerenih i modeliranih podataka je zadovoljavajuće (Slika 23d).





Slika 23: Izmjereni (plavo) i modelirani (crveno) vertikalni profili (a, c) temperature (T , °C) i (b, d) relativne vlažnosti (rh , %) postaje Zagreb – Maksimir za (a, b) 16.09.2017. u 12 UTC te (c, d) 17.09.2017. u 00:00 UTC

Statistička evaluacija rađena je također i za ovaj slučaj i to na dostupnim mjerenjima četiriju radiosondažnih postaja (Zagreb – Maksimir, Zadar, San Pietro Capofiume i Udine), i na podacima prizemnih postaja. Za radiosondažne podatke T (i ostalih parametara), radi bolje reprodukcije uvjeta u višim slojevima atmosfere, korelacija je vrlo visoka. Prizemne postaje pokazuju nižu korelaciju u vremenu za sve parametre. Za gotovo sve postaje, korelacija za T je veća od 0.5 (izuzetak je postaja Parg). Pogreške modela za temperaturu (MAE , $RMSE$) ispod su 4 °C. Pristranost modela je vrlo mala. Po visini, model uglavnom podcjenjuje T unutar intervala pristranosti od 0 °C do -2 °C (izuzetak su Udine 16.09.2017. u 12:00 UTC, gdje postoji malo precjenjivanje), dok kod vremenske usporedbe prizemnih nizova, postoji precjenjivanje T unutar intervala pristranosti od 0 °C do 3 °C.

Koeficijenti korelacije za brzinu vjetra za radiosondažne podatke su nešto niži nego za T , ali i dalje visoki. Puno je lošija korelacije brzine vjetra kod prizemnih postaja. Uglavnom je slaba i pozitivna (izuzetak su postaja Krapina i zračna luka Rijeka koji imaju slabu negativnu korelaciju). Pogreške modela za brzinu vjetra za prizemne postaje ne prelaze 3 m/s, dok su kod radiosondažnih podataka nešto veće (ističu se Zagreb 17.09.2017 u 00 UTC gdje je pogreška veća od 10 m/s i Zadar 17.09.2017. u 00 UTC s pogreškom oko 7 m/s).



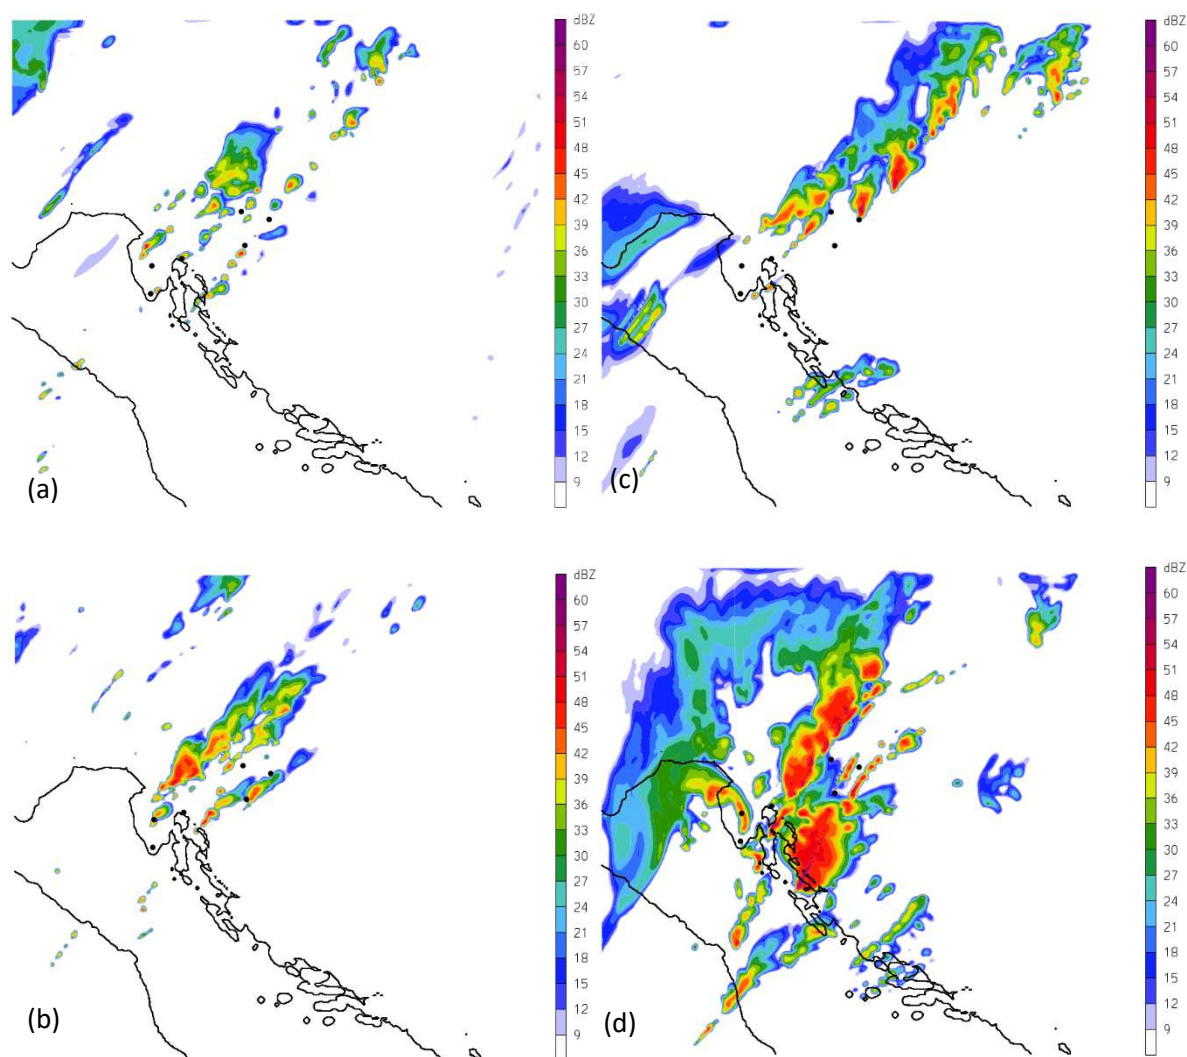
Slika 24: Statistički parametri za razdoblje 16.-17.09.2019.: (a) koeficijent korelacije (r), (b) srednja apsolutna pogreška (MAE), (c) korijen srednje kvadratne pogreške ($RMSE$) i (d) pristranost ($bias$) za brzinu vjetra (v , m/s; plavo), temperaturu (T , °C; crveno) i relativnu vlažnost (rh , %; žuto). Statistička evaluacija provedena je na podacima četiriju radiosondažnih postaja Zagreb-Maksimir, Zadar, San Pietro Capofiume i Udine (prvih 11 vrijednosti na x-osi), na prizemnim podacima 9 standardnih postaja u okviru mreže Državnog hidrometeorološkog zavoda te triju zračnih luka Pula, Rijeka i Zagreb.



Slika 24: Nastavak

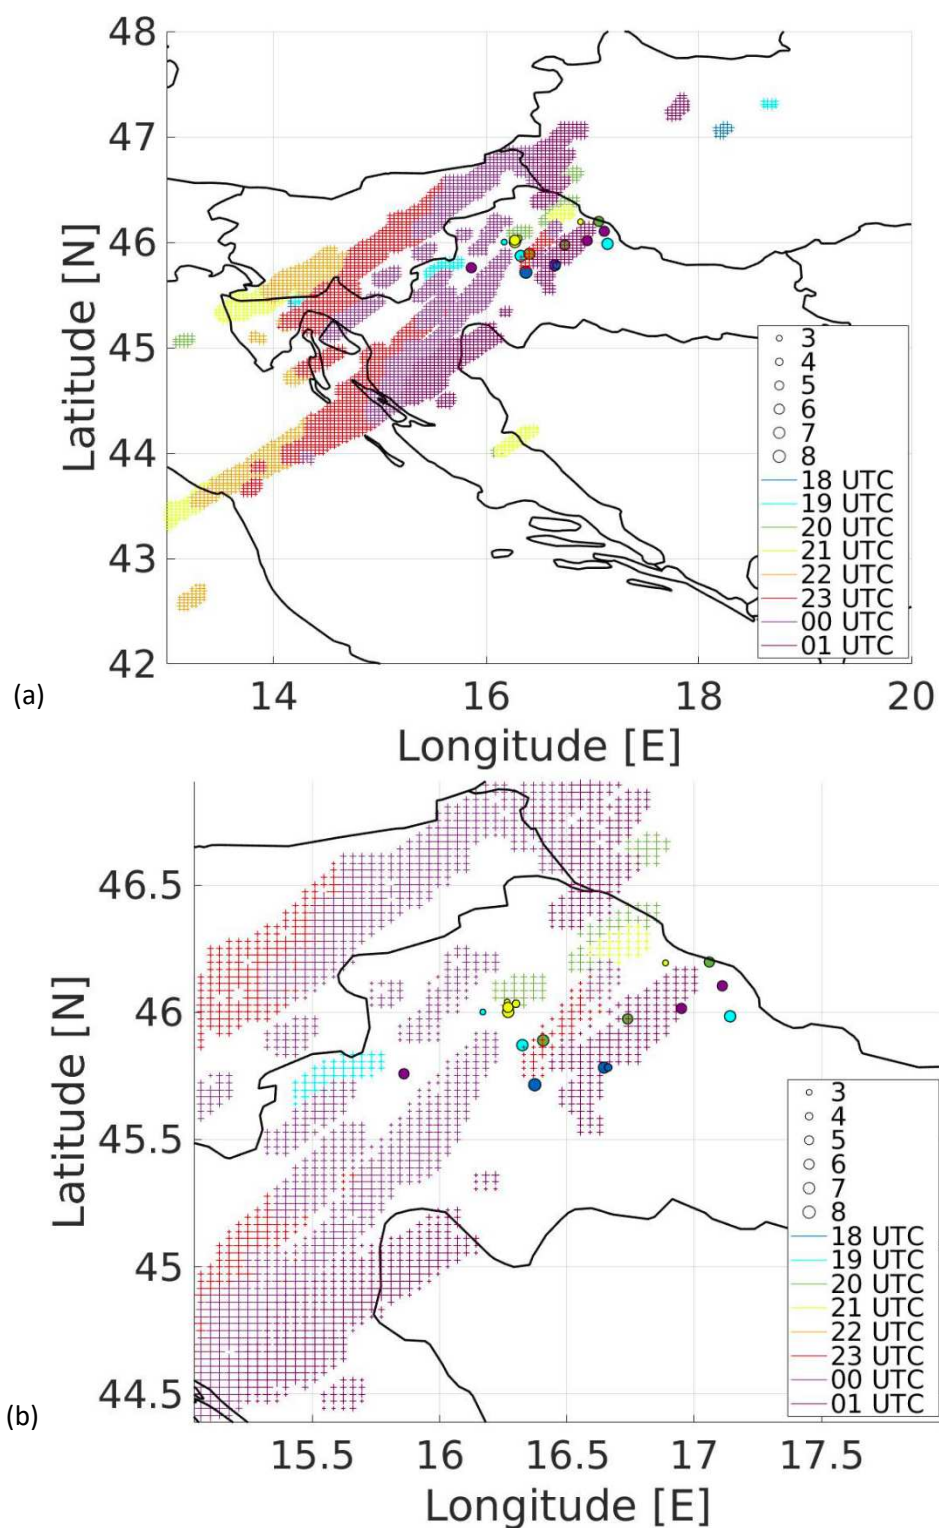
Slični kao kod brzine vjetra, korelacija radiosondažnih podataka za rh je visoka, dok je kod prizemnih postaja uglavnom mala i pozitivna (jedino zračna luka Rijeka ima negativnu i malu). Većina odstupanja rh su do 15% (MAE) odnosno do 20 % (RMSE). Model podcjenjuje vlažnost i po visini i u prizemnom sloju s izuzetkom postaje Pazin. Za prizemne postaje Rijeka, Zagreb Grič, Zagreb Maksimir i Mali Lošinj postoje najveće pogreške i pristranost za rh .

Iako ponašanje modela u odnosu na mjerenja ima slične i prihvatljive karakteristike prvom slučaju, drugi slučaj je nešto lošije simuliran modelom WRF-HAILCAST.



Slika 25: Modelirane vrijednosti maksimalnog radarskog odraza (dBZ) za 16.09.2017. u (a) 08:00 UTC, (b) 12:00 UTC, (c) 19:00 UTC, (d) 23:00 UTC. Crne točke označavaju postaje na kartama (slijeva nadesno): zračna luka Pula, Pazin, Rijeka, Krško, Karlovac i Zagreb

Modelirane vrijednosti maksimalnog radarskog odraza u jutarnjim satima (08:00 UTC, Slika 25a) ukazuju na mogućnost lokalne konvektivne aktivnosti u području gorske Hrvatske južno od Karlovca, dijelovima Istre i Slovenije, nad područjem Rijeke i u okolini Varaždina. Uspoređujući ih s izmjerenim vrijednostima (7 UTC, Slika 22a), model je dao preveliku vrijednost u području Varaždina, dok u slučaju područja oko Rijeke i u gorske Hrvatske postoji mali prostorni pomak. Iako postoje određene razlike u prognoziranom području te intenzitetu, u podne (Slika 25b), model je uspio uspješno reproducirati pojavu konvekcije u području Karlovca, gorske Hrvatske i Slovenije (Slika 22b). Rani večernji sati (Slika 22c) donose daljnji razvoj konvektivnog sustava u modelu, i to nad područjem sjeverozapadne Hrvatske i Slovenije (Slika 25c). Intenziteti maksimalnog radarskog odraza gotovo su isti, dok je položaj simulirane linije na kojoj se nalaze ćelije



Slika 26: Modelirani (križići) i izmjereni (kružići) maksimalni promjeri tuče na (a) čitavoj domeni (b) analiziranom području prekriveno mrežom tučomjera u razdoblju 18 – 01 UTC 16.09.2017. – 17.09.2017. Kružići odgovaraju razredima tuče od 3 do 8, a boje odgovaraju satima. Razredi rastu za svakih 2.5 mm počevši od 5 mm za 1. razred; 3. razred opisuje promjere zrna u intervalu vrijednosti 10-12.5 mm; 4. razred 12.5-15 mm, 5. razred 15-17.5 mm, 6. razred 17.5-20 mm, 7. razred 20-22.5 mm i 8. razred 22.5-25 mm. Najveći zabilježeni promjer zrna za ovaj slučaj je 23.1 mm

Tablica 3: Podaci o zabilježenoj tuči u razdoblju 18 UTC 16.09.2017. – 01 UTC 17.09.2017. i usporedba s (najbližim) modeliranim maksimalnim promjerom tuče (mm). U tablici maksimalni mjereni promjer zrna je označen s d (mm) i iz modela s d_{WRF} (mm).

Vrijeme	Šifra tučomjera	Geog. širina (°)	Geog. dužina (°)	Blizina većeg mjesta	Najveći broj zrna promjer (mm) /razred zrna	KE (J/m ²)	Vrijeme trajanja (min)	Ukupan broj zrna/m ²	Ukupna masa zrna (g/m ²)	Tok energije (W/m ²)	d (mm) /razred zrna	d_{WRF} (mm) /vrijeme
18-19 UTC	4001	16.6456	45.7825	Bjelovar	7.6-10 (2.)	49.4	4	736	555.0	205.9	22.4/7.	11.1 (01 UTC)
	4045	16.3732	45.7154	Ivanić Grad	10.1-12.5 (3.)	416.4	3	2544	3880.0	2313.4	23.1/8.	-
	4003	16.6619	45.7830	Čazma	7.6-10 (2.)	8.4	2	240	127.9	69.7	14.2/4.	-
19-20 UTC	9063	16.3246	45.8707	Sesvete	12.6-15(4.) 15.1-17.5 (5.)	235.3	5	1712	2379.4	784.4	21.1/7.	9.3 (23 UTC)
	J11	16.2688	46.0012	Sv. Ivana Zelina	7.6-10 (2.)	32.1	4	1264	539.5	535.2	15.0/4.	-
	3015	17.1411	45.9843	Đurđevac	10.1-12.5 (3.)	231.2	5	2224	2537.3	770.6	20.3/7.	-
	J08	16.1693	46.0011	Marija Bistrica	7.6-10 (2.)	30.3	10	2576	669.8	50.5	11.4/3.	-
20-21 UTC	9009	17.0593	46.1976	Koprivnica	12.6-15 (4.)	58.9	1	368	596.3	982.0	18.7/6.	-
	9069	16.4063	45.8896	Vrbovec	15.1-17.5 (5.)	174.7	5	688	1509.2	582.5	21.1/7.	10.1 (23 UTC)
	9080	16.7385	45.9740	Bjelovar	10.1-12.5 (3.)	192.0	10	2912	2472.6	320.0	19.1/6.	12.4 (01 UTC)
21-22 UTC	2086	16.2999	46.0335	Marija Bistrica	7.6-10 (2.)	17.5	1	448	260.4	291.1	14.0/4.	12.9 (20 UTC)
	J12	16.2688	46.0012	Sv. Ivana Zelina	10.1-12.5 (3.)	212.5	7	1600	2165.7	590.3	22.0/7.	13.6 (20 UTC)
	H12	16.2651	46.0403	Sv. Ivana Zelina	5-7.5 (1.)	6.0	2	464	124.8	50.0	11.9/3.	15.35 (20 UTC)
	I12	16.2680	46.0193	Sv. Ivana Zelina	7.6-10 (2.)	16.1	2	432	229.6	134.6	18.2/6.	13.6 (20 UTC)
	9007	16.8873	46.1939	Koprivnica	7.6-10 (2.)	5.2	1	224	96.4	87.6	11.6/3.	-
00-01 UTC	3007	16.9498	46.0153	Đurđevac	12.6-15 (4.)	231.7	11	2248	2640.1	351.1	18.4/6.	11.7 (01 UTC)
	3005	17.1102	46.1039	Đurđevac	10.1-12.5 (3.)	63.6	5	1024	790.4	211.9	18.7/6.	-
	3012	15.8593	45.7584	Zagreb	12.6-15 (4.)	104.8	3	1072	1190.7	582.1	18.7/6.	-

Cb-a lagano zakrenuta sjeverozapadno (NW) u odnosu na mjerenu. U noćnim satima uočavamo da se olujna nad analiziranim područjem nalaze zapadno od Karlovca, istočno od Zagreba i u okolini Bjelovara. Jak radarski odraz (> 48 dBZ) postoji i u području gorske Hrvatske te kvarnerskim otočjem (Slika 22g). Iako je model uspješno reproducirao konvekciju nad spomenutim područjem, prognozirao je puno veće područje konvekcije u gorskoj Hrvatskoj i nad područjem Slovenije.

Tijekom ovog razdoblja tuča je zabilježena u razdoblju od 18:33 do 22:00 UTC te od 00:00 do 0:51 UTC na 18 različitih postaja. U Tablici 3 se nalaze podaci o tuči po postajama slično kao i u Tablici 2. U posljednjem stupcu nalaze se modelirane vrijednosti maksimalnog promjera tuče i pripadno vrijeme prognoze u skladu sa Slikom 26. Vrijednosti su uzimane gdje postoji prostorno podudaranje modeliranih vrijednosti maksimalnog promjera tuče s izmjerenim. Od svih postaja u navedenom vremenskom razdoblju, maksimalni izmjereni promjer zrna tuče pripada 8. kategoriji tuče (22.5-25 mm) te iznosi 23,1 mm, a zrno je palo u blizini Ivanić Grada (Tablica 3). U trajanju od 3 minute, zabilježeno je 18 zrna na tučomjeru u 18:33 UTC; najveći tamnoplavi kružić; Slika 26b). Za tu postaju je ukupan broj zrna/m² jednak 2544, kinetička energija 416,4 J/m², tok energije 213,4 mW/m². Od svih postaja, najveći ukupni broj zrna/m² (2912) koji je pao u vremenu od 10 minuta je izmjeren u 20:45 UTC na postaji 9080 u blizini Bjelovara. KE je iznosila 192 J/m², a izmjerena masa jednaka je 2472,6 g/m². Zrna su klasificirana u 6 klasa, a najveći broj od 1008 zrna pripada 3. klasi (10-12,5 mm). Veći broj zrna povlačio je i veću masu i veću KE.

Modelirani i izmjereni maksimalni promjeri tuče na Slici 26 pokazuju precijenjenu rasprostranjenost tuče u modelu. Osim prostornih odstupanja, model je bio manje precizan i u vremenskoj domeni nastupa krute oborine. Budući da precijenjena prostorna raspodjela tuče može biti rezultat ograničenja modela, ali i ograničenog seta mjerenja, otvara se pitanje poboljšanja gustoće mjerenja tuče u budućem razdoblju.

4 Zaključak

U ovom radu su analizirani sinoptički i mezoskalni uvjeti selektiranih slučajeva koji su bili povezani s pojavom tuče. Odabir slučajeva temeljio se na dostupnim mjerenja tuče te klimatskim karakteristikama konvektivnog razvoja u Hrvatskoj. Dosadašnje su analize pokazale da je u dijelovima zapadne i središnje Hrvatske učestalost pojave i intenziteta konvektivne aktivnosti te tuče prilično velika. Ujedno su mjereni podaci o tuči dostupni uglavnom s lansirnih/radarskih postaja u sklopu obrane od tuče iz ravničarsko-nizinskog dijela Hrvatske. Uvažavajući navedeno, u prvom odabranom slučaju se analizirao 30. srpnja 2014. godine prilikom čega je tuča zabilježena poslijepodne između 14:00 i 17:00 UTC. U drugoj odabranoj epizodi analizirano je vremensko razdoblje od 16. do 17. rujna 2017. godine, a tuča je zabilježena u večernjim i noćnim satima, odnosno od 19:00 UTC prvoga dana do 01:00 UTC noći drugoga dana. Cilj je bio testirati i evaluirati mezoskalni numerički model koji je bio u mogućnosti eksplicitno dati informaciju o krutoj oborini, odnosno maksimalnom promjeru zrna tuče. Za tu je svrhu istraživačkoj verziji korištenog modela *Weather and Research Forecasting* (WRF) pridodana opcija simuliranja zrna tuče tzv. HAILCAST model (1-D model koji prognozira veličinu tuče koja padne na tlo). WRF-HAILCAST se bazira na promijenjenoj verziji modela oblaka i tuče.

Za provedbu usporedbe koristili su se svi dostupni prizemni i visinski (radiosondažni) podaci kao i podaci/slike daljinskih mjerenja (radara i mjerenja munja). Usporedba se vršila pomoću više standardnih statističkih parametara (MAE, RMSE, pristranost...). Od meteoroloških varijabli, korišteni su podaci prizemnog tlaka, smjera i brzine vjetra, temperature i relativne vlažnosti s 15 prizemnih postaja, triju zračnih luka i podaci četiriju radiosondažnih postaja. Nadalje, korišten je prikaz maksimalnog radarskog odraza kojeg daje ARSO radar Lisca/Pasja Ravan (<https://www.arso.gov.si/>) te podaci o broju udara munja iz LINET mreže mjerenja. Mjereni podaci o zabilježenoj tuči dobiveni su za prostor središnje i sjeverozapadne Hrvatske s lansirnih postaja i poligona.

Općenito za obje analizirane epizode, *WRF-HAILCAST* zadovoljavajuće reproducira vrijednosti temperature i brzine (i po visini i u vremenu), a najčešće griješi u slučaju relativne vlažnosti. Statistička vremenska usporedba prizemnih nizova je pokazala da model precjenjuje temperaturu u prizemnom dijelu graničnog sloja do 3 °C simulirajući topliju atmosferu od mjerene. Po visini reprodukcija temperaturnih profila je bila vrlo realistična sa zanemarivom pristranošću. U skladu s toplijim graničnim slojem prizemna vlažnost u modelu je bila niža od one mjerene s pogreškama najčešće do 10% za MAE i 15% za RMSE. Model je blago precjenjivao brzine strujanja s pogreškama do 3m/s što je unutar intervala pogrešaka za neke od odabranih parametrizacija koje su slične studije uočile (npr. Kehler-Poljak *et al.*, 2017).

Usporedba prostorno-vremenskih raspodjela konvektivne aktivnosti za oba slučaja pokazala je mogućnost modela da reproducira sinoptičke i mezoskalne uvjete u odabranim razdobljima. U slučaju prve opisane epizode iz 2014. godine, unatoč blagom precjenjivanju vrijednosti analiziranih parametara, model je uglavnom uspješno reproducirao atmosferske uvjete koji su pogodni za razvoj olujnog nevremena u području

središnje i sjeverozapadne Hrvatske. Iako je izmjeren maksimalni promjer tuče uspješno (prostorno i vremenski) prognozirano područje zahvaćeno tučom je preveliko. Isti problem prognoze prevelikog područja zahvaćenog tučom može se primijetiti i u slučaju iz 2017. godine. Međutim, u ovom slučaju model nije prognozirao tuču ondje gdje je zabilježena. Razlog je u manje točnim simuliranim oblačnim strukturama u prostoru čime je posljedično dobivena drugačija pojava tuče u odnosu na mjerenja.

Iako rezultati pokazuju da model daje bolju prognozu za epizodu iz 2014., usporedbu i razloge (bolje) uspješnosti iziskuje analizu većeg broja epizoda. Za očekivati je da pri korištenju istih parametrizacija model neće jednako uspješno reproducirati konvekciju i pojavu tuče za različite sinoptičke uvjete i različite tipove vremena. Stoga je u želji za dobivanjem uspješnijih i preciznijih simulacija potrebno provesti daljnju analizu u dva smjera. Prvi smjer bi uključivao analize epizode (ili nekoliko epizoda) uz mijenjanje parametrizacija osobito za granični sloj i mikrofizičke karakteristike oblaka. Drugi korak bi bio odabir skupa najoptimalnijih parametrizacija modela za uspješnije prognožiranje konvekcije/tuča nad Hrvatskom koji bi se primjenjivao na većem broju odabranih slučajeva.

Literatura

- Adams-Selin RD, Ziegler CL (2016.): Forecasting Hail Using a One-Dimensional Hail Growth Model within WRF. *Mon. Weather Rev.*, **144**, 4919-4939.
- Belušić A, Telišman Prtenjak M, Güttler I, Ban N, Leutwyler D, Schär C (2018.): Near-surface wind variability over the broader Adriatic region: insights from an ensemble of regional climate models. *Clim. Dyn.* **50**, 4455-4480.
- Betz HD, Schmidt K, Laroche P, Blanchet P, Oettinger WP, Defer E, Dziewit Z, Konarski J (2009.): LINET—An international lightning detection network in Europe. *Atmos. Res.*, **91**, 564–573.
- Brimelow JC, Reuter GW, Poolman ER (2002.): Modeling maximum hail size in Alberta thunderstorms. *Weather Forecast.*, **17**, 1048–1062.
- Browning, KA (1977.): The structure and mechanisms of hailstorms. Hail: A Review of Hail Science and Hail Suppression, *Meteor. Monog.*, No. 38. Amer. Meteor. Soc., 1-43
- Byers HR i Braham RR (1949.): The thunderstorms, U.S. Govt. Printing Office, Washington D.C., USA, 287 str.
- Cotton WR, Bryan GH, Van den Heever S (2010.): Storm and Cloud Dynamics. Second edition. Academic Press, USA
- Ćurić M, Janc D (2016.): Hail climatology in Serbia. *Int. J. Climatol.*, **36**, 3270-3279.
- Dennis AS, Schock CA and Koscielski A (1970.): Characteristics of hailstorms of western South Dakota. *J. Appl. Meteor.*, **9**: 127-135.
- Doswell CA, Moller AR, Przybylinski R (1990.): A unified set of conceptual models for variations on the supercell theme. Preprints, 16th Conf. on Severe Local Storms, Kananaskis Park, Alberta, Canada, Amer. Meteor. Soc., 40–45.
- Dudhia J (1989.): Numerical study of convection observed during the winter monsoon experiment using a mesoscale two-dimensional model. *J. Atmos. Sci.*, **46**, 3077–3107.
- Foote GB, Wade CG (1982.): Case study of a hailstorm in Colorado. Part I: Radar echo structure and evolution. *J. Atmos. Sci.*, **39**, 2828–2846.
- Gajić-Čapka M, Zaninović K (1993.): Vremenske promjene pojave tuče i grmljavine na području Bjelovara, Križevaca i Čazme. *Hrv. meteorol. časopis*, **28**, 59-64.
- Heymsfield AJ, Jameson AR, Frank, HW (1980.): Hailgrowth mechanisms in a Colorado storm. Part II: Hail formation processes. *J. Atmos. Sci.*, **37**, 1779–1813.
- Holleman I (2001.): Hail Detection Using Single-polarization Radar. Ministerie van Verkeer en Waterstaat, Koninklijk Nederlands Meteorologisch Instituut.
- Houze RA (2014.) Cloud Dynamics. 2nd Edition, Academic Press, USA
- Jalu R (1959.): Orages et chutes de grêle du 11 août 1958 à Strasbourg. *La Météorologie IV*, 209–220.
- Jewell R, Brimelow J (2009.): Evaluation of Alberta hail growth model using severe hail proximity soundings from the United States. *Weather Forecast.*, **24**, 1592–1609.
- Kain JS, Fritsch JM (1993.): Convective parameterization for mesoscale models: The Kain-Fritsch scheme, The representation of cumulus convection in numerical models, K. A. Emanuel and D.J. Raymond, Eds., American Meteorological Society, 246 pp.
- Kehler-Poljak G, Telišman Prtenjak M, Kvakić M, Šariri K, Večenaj Ž (2017): Interaction of sea breeze and deep convection over the northeastern Adriatic coast: an analysis of sensitivity experiments using a high-resolution mesoscale model. *Pure Appl. Geophys.* **174**, 4197-4224.
- Kolkowska K, Lorenc H (2012.): Klęski żywiołowe a Bezpieczeństwo Wewnętrzne Kraju. Instytut Meteorologii i Gospodarki Wodnej Państwowy Instytut Badawczy, Warszawa, pp. 80–97
- Ch. Ryzyko występowania gradu w Polsce. [in Polish]. Dostępno na: <http://klimat.imgw.pl/wp-content/uploads/2013/01/tom3.pdf> [30. listopada 2019.]
- Kuraži D, Počakal D (2016.): Karakteristike zrna tuče u sjeverozapadnom dijelu Hrvatske. *Hrv. meteorol. časopis*, **51**, 3-11.
- Manzato A (2012.): Hail in northeast Italy: climatology and bivariate analysis with the sounding-derived indices. *J. Appl. Meteorol. Clim.*, **51**, 449–467.

- Mezeix JF, Doras N. (1981.): Various kinetic energy characteristics of hailpatterns in the Grossversuch IV experiment. *J. Appl. Meteorol. Clim.*, **20**, 179-186.
- Mikuš, P., Telišman Prtenjak, M., Strelec Mahović, N. (2012.) Analysis of the convective activity and its synoptic background over Croatia. *Atmos. Res.*, **104/105**, 139-153.
- Mikuš Jurković P, Strelec Mahović N, Počakal D (2015.): Lightning, Overshooting Top and Hail Characteristics for Strong Convective Storms in Central Europe. *Atmos. Res.*, **161/162**, 153-168.
- Morgan GM (1973.): A general description of the hail problem in the Po Valley of northern Italy *J. Appl. Meteorol. Clim.*, **12**, 338-353.
- Morrison H, Milbrandt JA (2015.): Parameterization of cloud microphysics based on the prediction of bulk ice particle properties. Part I: Scheme description and idealized tests. *J. Atmos. Sci.*, **72**, 287-311.
- Morrison H, Thompson G, Tatarskii V (2009.): Impact of cloud micropohysics on the development of trailing stratiform precipitation in a simulated squall line: Comparison of one- and two-moment schemes. *Mon. Wea. Rev.*, **137**, 991-1007.
- Palencia C, Berthet C, Massot M, Castro A, Dessens J, Fraile R (2007.): On the individual calibration of hailpads. *Atmos. Res.*, **83**, 493-504.
- Paškvan, R. (1955.): Tuča i njena učestalost u Istri i užem području Poreča. *Agronomski glasnik*, **5**, 176-184.
- Penzar B, Penzar I, Orlić M (2001.): *Vrijeme i klima hrvatskog Jadrana*. Nakladna kuća "Dr. Feletar", Hrvatski hidrografski institute, Zagreb
- Počakal, D (2012.): Energija zrna tuče u kontinentalnom dijelu Hrvatske. Doktorski rad. Zagreb: Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet.
- Počakal D, Večenaj Ž, Mikuš Jurković P, Grisogono B (2018.): Analysis of orographic influence on hail parameters in NW Croatia. *Int. J. Climatol.*, **38**, 5646-5658.
- Poolman ER (1992.): The forecasting of hail growth in South Africa. Magistarski rad. Južnoafrička Republika: University of Pretoria, Faculty of Engineering
- Porrás I, Sairouni A, Aran M (2013): Climatologia de la probabilitat de calamarsa a Catalunya. [in Catalan]. Dostupno na: <https://static-m.meteo.cat/wordpressweb/wp-content/uploads/2014/11/18130754/nota-estudi-climatologia-calamarsa-n74.pdf> [30. listopada 2019.]
- Punge HJ, Bedka K, Kunz M, Werner A (2014.): A new physically based stochastic event catalog for hail in Europe. *Nat. Hazards*, **73** (3), 1625-1645.
- Punge HJ, Kunz M (2016.): Hail observations and hailstorm characteristics in Europe: A review. *Atmos. Res.*, **176-177**, 159-184.
- Rasmussen RM, Heymsfield AJ (1987.): Melting and shedding of graupel and hail. Part I: Model physics. *J. Atmos. Sci.*, **44**, 2754-2763.
- Schleusener RA, Jennings PC (1960.): An energy method for relative estimates of hail intensity. *Bull. Amer. Meteor. Soc.*, **41**, 372-376.
- Stržinar G, Skok G (2018.): Comparison and optimization of radar-based hail detection algorithms in Slovenia. *Atmos. Res.*, **203**, 275-285.
- Tuovinen J, Punkka A, Rauhala J, Hohti H, Schultz DM (2009.): Climatology of severe hail in Finland: 1930-2006. *Mon. Wea. Rev.*, **137**, 2238-2249.
- Vali G, Stansbury EJ (1965.): Time-dependent characteristics of the heterogeneous nucleation of ice. Science Rep. MW-41, McGill University, Montreal, QC, Canada, 31 pp.
- Zaninović K, Gajić-Čapka M, Perčec Tadić M, Vučetić M, Milković J, Bajić A, Cindrić K, Cvitan L, Katušin Z, Kaučić D, Likso T, Lončar E, Lončar Ž, Mihajlović D, Pandžić K, Patarčić M, Srnc L, Vučetić V (2008.): Klimatski atlas Hrvatske / Climate atlas of Croatia 1961-1990., 1971-2000. Državni hidrometeorološki zavod, Zagreb. 200 str.
- WMO, (1975.): International Cloud Atlas, WMO-No. 407, 180 Dostupno na: <https://cloudatlas.wmo.int/home.html> [30. listopada 2019.]
- WMO, (1992.): International Meteorological Vocabulary, WMO, 784

